Income Statistics Division

75F0002MIE - 00004

Longitudinal and Cross-Sectional Weighting of the Survey of Labour and Income Dynamics 1997 Reference year

Prepared by:
Isabelle Lévesque
Sarah Franklin

August 2000

Statistics Canada Statistique Canada

Canada

Data in many forms

Statistics Canada disseminates data in a variety of forms. In addition to publications, both standard and special tabulations are offered. Data are available on the Internet, compact disc, diskette, computer printouts, microfiche and microfilm, and magnetic tape. Maps and other geographic reference materials are available for some types of data. Direct online access to aggregated information is possible through CANSIM, Statistics Canada's machine-readable database and retrieval system.

How to obtain more information

Inquiries about this product and related statistics or services should be directed to: Client Services Income Statistics Division Canada, Ottawa, Ontario, K1A 0T6 ((613) 951-7355; (888) 297-7355; income@statcan.ca) or to the Statistics Canada Regional Reference Centre in:

Halifax	(902) 426-5331	Regina	(306) 780-5405
Montréal	(514) 283-5725	Edmonton	(403) 495-3027
Ottawa	(613) 951-8116	Calgary	(403) 292-6717
Toronto	(416) 973-6586	Vancouver	(604) 666-3691
Winnipeg	(204) 983-4020		

You can also visit our World Wide Web site: http://www.statcan.ca

Toll-free access is provided **for all users who reside outside the local dialing area** of any of the Regional Reference Centres.

National enquiries line	**1 800 263-1136**
National telecommunications device for the hearing impaired	**1 800 363-7629**
Order-only line (Canada and United States)	**1 800 267-6677**

Ordering/Subscription information

All prices exclude sales tax

Catalogue no. 75F0002MIE-00004, is available on internet for CDN $0.00 per issue. Users can obtain single issues at http://www.statcan.ca/cgi-bin/downpub/freepub.cgi.

Standards of service to the public

Statistics Canada is committed to serving its clients in a prompt, reliable and courteous manner and in the official language of their choice. To this end, the agency has developed standards of service which its employees observe in serving its clients. To obtain a copy of these service standards, please contact your nearest Statistics Canada Regional Reference Centre.

Statistics Canada
Income Statistics Division

Longitudinal and Cross-Sectional Weighting of the Survey of Labour and Income Dynamics 1997 Reference Year

Published by authority of the Minister responsible for Statistics Canada

© Minister of Industry, 2000

All rights reserved. No part of this publication may be reproduced, stored in a retrieval system or transmitted in any form or by any means, electronic, mechanical, photocopying, recording or otherwise without prior written permission from Licence Services, Marketing Division, Statistics Canada, Ottawa, Ontario, Canada K1A 0T6.

August 2000

Catalogue no. 75F0002MIE - 00004
ISSN 0000-0000

Catalogue no. 75F0002MPE - 00004
ISSN 0000-0000

Frequency: Irr

Ottawa

La version française de cette publication est disponible sur demande

---

Note of appreciation

Canada owes the success of its statistical system to a long-standing partnership between Statistics Canada, the citizens of Canada, its businesses, governments and other institutions. Accurate and timely statistical information could not be produced without their continued co-operation and goodwill.

ELECTRONIC PUBLICATIONS AVAILABLE AT
www.statcan.ca

ABSTRACT

The Survey of Labour and Income Dynamics (SLID), introduced in the 1993 reference year, is a longitudinal panel survey of individuals. The purpose of the survey is to measure changes in the economic well-being of individuals and the factors that influence these changes. SLID's sample is divided into two overlapping panels, each six years in length. Longitudinal surveys like SLID are complex due to the dynamic nature of the sample, which is in turn is due to the ever-changing composition of households and families over the years. For each reference year, SLID produces two sets of weights: one is representative of the initial population (the longitudinal weights) while the other is representative of the current population (the cross-sectional weights). For the production of the cross-sectional weights, SLID combines two independent samples and assigns a probability of selection to individuals who joined the sample after the panel was selected. The longitudinal weights, like the cross-sectional weights, are adjusted for nonresponse, influential values, post-stratification and confidentiality. The purpose of this document is to describe SLID's methodology for the longitudinal and cross-sectional weights, as well as to present problems that have been encountered and solutions that have been proposed. For the purpose of illustration, results for the 1997 reference year are used.

TABLE OF CONTENTS

1. Introduction 9

2. Survey Methodology 11

3. Longitudinal Weighting 17
   - 3.1 Determination of Initial Weights 17
   - 3.2 Classification of Longitudinal Individuals 18
   - 3.3 Nonresponse Modelling and Adjustment 19
   - 3.4 Adjustment for Influential Values 23
   - 3.5 Post-stratification 24
   - 3.6 Addition of Noise 25
   - 3.7 Description of the Final Longitudinal Weights 26

4. Cross-sectional Weighting 29
   - 4.1 Determination of Individuals who are Eligible for Cross-sectional Weighting 29
   - 4.2 Nonresponse Adjustment 30
   - 4.3 Application of Panel Allocation Factors 30
   - 4.4 Weight Share 34
   - 4.5 Adjustment for Interprovincial Migration 36
   - 4.6 Adjustment for Influential Values 37
   - 4.7 Post-stratification 39
   - 4.8 Addition of Noise 40
   - 4.9 Description of the Final Cross-sectional Weights 40

5. Forthcoming Changes and Future Developments 43

6. Conclusion 45

Acknowledgements 47

References 49

Appendix A: List of Variables Used in the Nonresponse Adjustment Model 51

1. Introduction

The Survey of Labour and Income Dynamics (SLID), introduced in the 1993 reference year, is a longitudinal panel survey of individuals. Its goal is to measure changes in the economic well-being of individuals and the factors that influence those changes, especially key factors in the areas of demographic and family characteristics and labour market activity. Its end product is a set of microdata files. For an overview of the survey, see Lavigne and Michaud (1998).

Originally, SLID was intended to provide longitudinal data to be used in producing longitudinal estimates and analyses. Its cross-sectional dimension has now become just as important as its longitudinal one, in part because the Survey of Consumer Finances (SCF), a cross-sectional survey, has been merged with SLID (Cotton et al., 1999). The two surveys were integrated for the 1998 reference year. For more information about SCF, see Statistics Canada, 1997.

Weighting a longitudinal survey can sometimes be a major methodological challenge, not only because of its longitudinal and cross-sectional dimensions but also because of the dynamic nature of the panel (which is in turn due to the ever-changing composition of families and households). Many weighting problems have arisen through the years, and there will be others in the future: the combining of overlapping panels, the integration of SCF, the change in software used to model nonresponse, the increase in the number of age-sex post-strata and the introduction of new post-strata (number of economic entities, income groups), changes in data processing, etc. All these considerations add to the complexity of SLID's longitudinal and cross-sectional weighting.

The main purpose of this document is to describe the various steps in the longitudinal and cross-sectional weighting processes for the 1997 reference year. Our second aim is to document certain concerns and questions about a few of the weighting steps. Our third objective is to inform the reader of future developments and major changes affecting weighting. The document consists of five sections. The survey's methodology is discussed in section 2. Section 3 presents the steps in the longitudinal weighting process, from determination of the initial weights to calculation of the final ones, while section 4 covers the various steps in the cross-sectional weighting process. Section 5 looks ahead to the future, and section 6 contains the document's conclusion.

This document is partly based on previous reports on SLID's weighting (Grondin, 1996; Gagnon, 1997; Renaud, 1997). The latter documents cover the 1993 and 1994 reference years. As the longitudinal and cross-sectional weighting methodology has undergone a number of changes and innovations since then, an updated version was deemed necessary.

2. Survey Methodology

SLID sample is composed of two panels, each six years (or six waves) in length. Panel 1, selected in January 1993, covers the population living in the 10 Canadian provinces on December 31, 1992. Panel 2, chosen in January 1996, represents the provinces' population on December 31, 1995. In both cases, the population excludes persons living on Indian reserves, full-time members of the Canadian Armed Forces, and persons who had been living in an institution for more than six months. All references to the population of the 10 Canadian provinces in this document automatically imply all the above exclusions.

A new panel is introduced every three years to replace the oldest panel. The purpose of this rotation is to make the cross-sectional sample more representative (to reflect the new households added to the population in the preceding three years), to mitigate the effect of attrition, and to reduce response burden. Panel selection and overlap is illustrated in Figure 2.1.

Figure 2.1: Overlap of SLID Panels

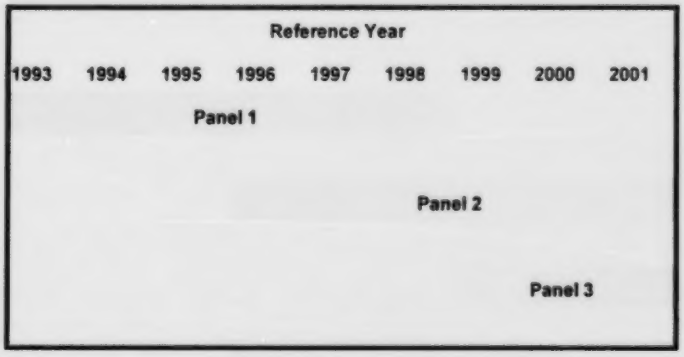

Each SLID panel consists of a subsample of about 15,000 households (roughly 40,000 people) from the Labour Force Survey (LFS). The LFS sample is drawn from an area frame in accordance with a multistage sampling design. The LFS has six panels (rotation groups); each panel remains in the sample for six months, with one panel replaced each month. The last-stage sampling unit is the dwelling. Thus, all members of the households occupying the selected dwellings are included in the LFS sample. For further information about the LFS, see the reports on its methodology (Singh et al., 1990; Gambino et al., 1998).

The households selected for SLID belong to the panels that rotated out of the LFS sample in the first two months of SLID's first reference period (January and February 1993 for Panel 1, and January and February 1996 for Panel 2). SLID's initial sample is chosen from the LFS file for January. Of all the households that make up the outgoing LFS rotation groups in January and February, SLID selects only those which were LFS respondents in January. The final LFS interview serves as the introductory contact for SLID. A preliminary interview is conducted with each person selected by SLID. Basic information about work experience, level of education, and family and personal background is collected in the interview.

For Panel 1, the preliminary SLID interview was conducted at the same time as the final LFS interview. Because of budget constraints, households that responded in the preliminary interview had to be subsampled; the longitudinal sample for Panel 1 includes only members

of those households. A subsample of interview nonespondents was also selected so that nonresponse bias could be studied. Data were collected for those households, but were not used for production. This subsample will not be discussed here.

For Panel 2, the preliminary interview was conducted at the same time as SLID's wave 1 interviews in order to reduce collection costs. The longitudinal sample for Panel 2 includes everyone who underwent a preliminary interview (respondents and nonrespondents). Figures 2.2 and 2.3 illustrate SLID's household selection process. More details on the selection of SLID panels are provided in subsection 3.1

Figure 2.2: Selection of Households for SLID Longitudinal Sample - Panel 1

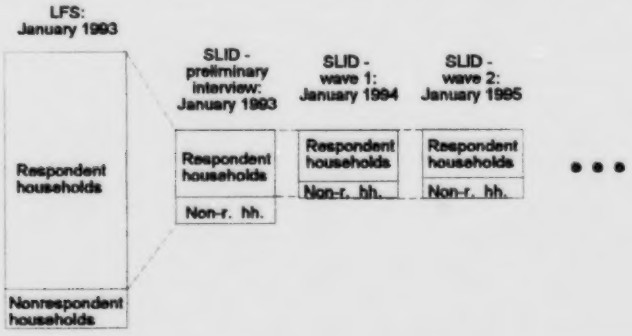

Figure 2.3: Selection of Households for SLID Longitudinal Sample - Panel 2

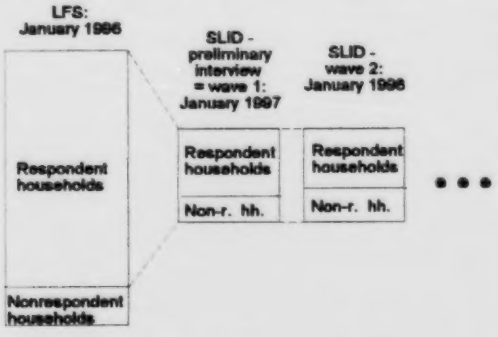

Each person selected for SLID is then interviewed twice a year for six years. Each year, information is collected about family and household composition, labour market activity and the previous year's income. The labour market questions are asked in January, and the income questions, in May. To reduce the response burden, respondents can avoid the May interview by preauthorizing Statistics Canada to access their Revenue Canada tax file.

When a panel is selected for SLID, every member of the households chosen, regardless of age, becomes part of the panel's longitudinal sample. These persons are considered part of the longitudinal sample for the panel's full six years, even if they move, die, are institutionalized or become full-time members of the Armed Forces living in military quarters. No one else can join the longitudinal sample for this panel. Thus, for each panel,

the longitudinal sample is formed when the panel is selected and remains unchanged for the life of the panel. The sample's target population will stay the same throughout the six years that the panel is part of the survey.

For longitudinal purposes, the unit of interest is the individual; because of its constantly changing nature, a household can hardly be used as a tool for longitudinal analysis. For cross-sectional purposes, we are interested in both the individual and the household. Since SLID is concerned with the characteristics not only of longitudinal persons but also of households, everyone who lives with at least one longitudinal individual is interviewed. Hence, the cross-sectional sample for a given year is composed of all longitudinal persons in scope on December 31 of the corresponding reference year, and all persons living with them on that date. An individual is considered in scope on December 31 of a given reference year (cross-sectionally in scope) if on that date, he or she lives in one of the 10 Canadian provinces, does not live on an Indian reserve, has not been living in an institution for more than six months, and is not a full-time member of the Canadian Armed Forces living in military barracks. Every cross-sectionally in-scope longitudinal person will also be part of the cross-sectional sample. Interviewees who are not part of the longitudinal sample are called cohabitants. Adding cohabitants to the cross-sectional sample helps make it more representative (Latouche, Michaud, 1997).

To meet the above-mentioned requirements, longitudinal and cross-sectional weights are produced each year. Longitudinal weighting is designed to generate estimates that are representative of the population of Canada's 10 provinces at the time the longitudinal sample is selected, while cross-sectional weighting produces estimates that are representative of the provinces' population on December 31 of a given reference year. For example, the estimates based on Panel 1's longitudinal sample are representative of the provinces' population on December 31, 1992, and the estimates produced with Panel 2's longitudinal sample relate to the provinces' population on December 31, 1995. The estimates based on the cross-sectional sample for the 1997 reference year represent the provinces' population on December 31, 1997.

In January 1993, 39,745 persons were selected for Panel 1's longitudinal sample. In January 1996, 43,547 persons were chosen for Panel 2's longitudinal sample. The cross-sectional sample for the 1997 reference year consists of 81,090 individuals, 70,372 of whom are longitudinal persons.

Table 2.1 provides an overview of how the longitudinal samples have changed over time. Table 2.2 shows the composition of the cross-sectional samples of all reference years considered (1993 to 1997 inclusive).

Table 2.1: Composition of the Longitudinal Samples of Panels 1 and 2 (Number of Persons)

Reference year		1993	1994	1995	1996	1997
	Persons contacted at interview					
	In-scope on December 31 of the reference year[1]	39 456	36 241	34 336	33 159	31 802
	Living outside the 10 Canadian provinces	28	37	45	150	280
	Institutionalized	81	119	278	256	280
Panel 1	Deceased	180	408	657	908	1 134
	Duplicate, error	0	0	1	1	1
	Persons not contacted at interview[3]					
	Hard refusal, persons in households not traced[2]	0	2940	4428	5271	6 248
	Total	39 745	39 745	39 745	39 745	39 745
	Persons contacted at interview					
	In scope on December 31 of the reference year[1]	----	----	----	41 767	38 366
	Living outside the 10 Canadian provinces	----	----	----	126	270
	Institutionalized	----	----	----	40	120
Panel 2	Deceased	----	----	----	234	466
	Duplicate, error	----	----	----	0	2
	Persons not contacted at interview[3]					
	Hard refusal, persons in households not traced	----	----	----	1 380	4 323
	Total	----	----	----	43 547	43 547

1 Still living in the 10 Canadian provinces, not deceased, not living in an institution for more than last six months.

2 Does not include refusals at SLID preliminary interview and the LFS interview.

3 Prior to the 1997 reference year, this category includes hard refusals and not-traced during collection for a given reference year. For the 1997 and subsequent reference years, all cases in this category relate to previous collection.

Table 2.2: Composition of Cross-sectional Samples, by Panel (Number of Persons)

Reference year	1993	1994	1995	1996	1997
Panel 1					
Longitudinal persons	39 456	36 241	34 336	33 159	31 802
Cohabitants	2 062	3 640	4 620	5 768	6 655
	41518	39881	38956	38927	38457
Panel 2					
Longitudinal persons	----	----	----	41767	38366
Cohabitants	----	----	----	2 351	4 011
	----	----	----	44118	42377
Total	41 518	39 881	38 956	83 045	80 834

SLID's mandate is to collect longitudinal and cross-sectional data on labour-market and income characteristics and to make the data available to users inside and outside Statistics Canada. For the latter purpose, SLID produces two sets of microdata files: one anonymized to preserve confidentiality (external files) and one not anonymized (internal files). The internal files are available only to Statistics Canada users, as they contain weights that have not been anonymized (*internal weights*). External files, produced for users outside Statistics Canada, are anonymized through the addition of noise to all the weights (*external weights*).

Once the data for a given reference year have been processed, Statistics Canada users can access the relational database to perform their cross-sectional and longitudinal analyses. All information in the database is confidential since it has not been anonymized. Internal and external weights, as well as some other anonymized data, are also included in the database.

Internal cross-sectional and longitudinal files are also produced to make the data easier for Statistics Canada users to access. Releasing external files takes more work because they must be anonymized. All disclosure control procedures are reviewed and improved in order to ensure data confidentiality. For the 1997 reference year, the original dissemination strategy was to produce a set of public-use cross-sectional and longitudinal microdata files.

The cross-sectional files (which relate to the reference year in question) cover everyone (longitudinal persons and cohabitants) aged 16 and over in respondent households that are in scope on December 31 of the reference year concerned. The longitudinal files (which contain information for all reference years, from the first one to the most recent one) include all longitudinal persons regardless of status. The two sets of files have very similar contents. One feature of this dissemination strategy is that to maintain confidentiality, it prohibits the publication of microdata files that can be used to reconstruct households. Because of time constraints, the microdata for the 1997 reference year have not yet been released.

3. Longitudinal Weighting

This section describes the methodology used to weight the longitudinal persons in each wave of SLID. For illustrative purposes, we will use examples from wave 5 of Panel 1 and wave 2 of Panel 2. It is important to keep in mind that the longitudinal weights are intended to represent the population of Canada's ten provinces on December 31, 1992, for Panel 1 and on December 31, 1995, for Panel 2.

SLID produces two sets of longitudinal weights: a set of internal weights and a set of external weights. The external weights are for users outside Statistics Canada. Noise is added to these weights prevent the reconstruction of families and households. The two sets of longitudinal weights are produced separately for the two panels.

The longitudinal weighting process consists of the six steps discussed in the following subsections: determination of initial weights (3.1), classification of longitudinal individuals (3.2), nonresponse modelling and adjustment (3.3), adjustment for influential values (3.4), post-stratification (3.5) and the addition of noise (3.6). The resulting final longitudinal weights are described in subsection 3.7.

3.1 Determination of Initial Weights

For the first SLID sample (Panel 1), respondent households from the two outgoing LFS rotation groups in January and February 1993, a total of 20,486 households, were selected. Of these, 17,659 households responded at SLID's preliminary interview, and the remaining 2,827 were nonrespondent households. For budget reasons, the decision was made to reduce the initial SLID sample to about 15,000 households. To this end, the respondent households were subsampled using a Poisson process with a parameter of 0.84. The nonrespondent households were also subsampled using a Poisson process, but in this case the parameter was 0.06. This resulted in a reduced sample of 14,832 respondent households (39,745 persons) and 174 nonrespondent households (410 persons).

For budget reasons, only the respondent households (14,832) were selected for the initial sample in Panel 1. A study showed that this decision would have a relatively minor impact (Durning, 1994). Though excluded from the final sample, the 174 nonrespondent households were retained for analysis. These households form what is called a quality sample. This sample will not be discussed in the present document.

The sample for Panel 2 was selected in a much simpler way: all households that responded to the LFS in January 1996 and belonged to the outgoing LFS rotation groups for January and February 1996 were selected (16,472 households totalling 43,547 persons). The preliminary interviews for Panel 2 were conducted at the same time as the wave 1 interviews (that is, in January 1997).

The initial longitudinal weights are equal to the households' inverse selection probability Thus, all longitudinal members of a household (the one to which they belonged at the time the sample was selected) have the same initial weight.

Since SLID sample is drawn from the LFS sample, the initial weight will be as follows:

$$w_{initial,p_1} = w_{LFS} * 3 * 1.19$$
$$w_{initial,p_2} = w_{LFS} * 3$$

where $w_{initial,p_1}$ = initial longitudinal weight for Panel 1
$w_{initial,p_2}$ = initial longitudinal weight for Panel 2
w_{LFS} = LFS weight adjusted for nonresponse (LFS subweight)
3 = inverse selection probability of the LFS rotation groups (2 out of 6 groups were selected)
1.19 = inverse sampling ratio of the subsample of respondents at the preliminary interview for Panel 1 (selected using a Poisson process).

3.2 Classification of Longitudinal Individuals

For each wave, the first step in longitudinal weighting is to place the longitudinal individuals in one of the following categories: nonrespondents (in respondent or nonrespondent households), cross-sectionally in-scope respondents, and cross-sectionally out-of-scope persons. A household is defined as respondent if at least one household member responded to at least one of the two interviews (the labour interview or income interview). A household is considered nonrespondent if all household members are nonrespondents at both interviews. A person is deemed cross-sectionally out of scope if, on December 31 of the reference year, he or she was deceased, had been in an institution for more than six months, or was not living in one of Canada's ten provinces.

The classification of longitudinal individuals is necessary in order to determine which ones should be assigned a non-zero longitudinal weight. A longitudinal weight of zero is applied to individuals in nonrespondent households. All other individuals initially selected for the longitudinal sample have a non-zero longitudinal weight, even if they are cross-sectionally out of scope (since they are considered to be respondents). It should be noted that for weighting purposes, SLID defines nonrespondent persons in respondent households as respondent. This is to ensure weighting consistency within households (the data for nonrespondent persons in respondent households are imputed).

The classification of longitudinal individuals also determines whether an individual's weight should be adjusted for nonresponse and identifies those individuals who will be used in the nonresponse adjustment model. The purpose of this model is to find the value by which respondents' weights must be adjusted to make them representative of all respondents and nonrespondents.

Nonresponse adjustments are usually applied to the weights of all respondent units in a survey. In SLID, a nonresponse adjustment factor is applied to the weights of all persons considered to be respondent, except children in respondent households and cross-sectionally out-of-scope persons. A nonresponse adjustment factor is not used for cross-sectionally out-of-scope persons because the number of such persons is already overestimated (Franklin, 1999b). Children's weights are not adjusted for nonresponse because too little information is collected about children to properly model nonresponse. A nonresponse adjustment is made implicitly at post-stratification.

Table 3.1 shows the various response categories of the longitudinal individuals in wave 5 of Panel 1 and wave 2 of Panel 2. The *Nonresponse modelling* column indicates which categories of individuals are used in the nonresponse adjustment model. The last three columns show how the weights of individuals in the various categories will be processed.

Table 3.1: Classification of Longitudinal Individuals in Wave 5 of Panel 1 and Wave 2 of Panel 2

	Classification of individuals	Panel 1 wave 5	Panel 2 wave 2	Nonresponse modelling	$W_{adjust} = 0$	$W_{adjust} = W_{initial}$ (unadjusted)	$W_{adjust} = W_{initial}/R_{RHG}$ (adjusted)
CHILDREN	In a nonrespondent household	1 043	1 057		●		
age 0-15 (on Dec. 31, 1997)	In a respondent household	5 530	7 986			●	
	In a cross-sectionally out-of-scope household (deceased, institutionalized or outside the provinces)	39	65			●	
	Cross-sectionally out of scope (institutionalized, deceased or outside the provinces)	1 513	705			●	
ADULTS	Respondents	25 819	29 002	✔			●
age 16 + (on Dec. 31, 1997)	Nonrespondents in a nonrespondent household	5 648	4 407	✔	●		
	Duplicate, error	1	2		●		
	Nonrespondents in a respondent household (will be imputed)	151	323				●
	Quality sample[1]	411	-----		●		
	Total	40.155	43.547				

3.3 Nonresponse Modelling and Adjustment

Having generated the initial weights, we now have to compute a nonresponse adjustment factor for every individual deemed to be a respondent except for children in respondent households and cross-sectionally out-of-scope persons. As noted earlier, the two panels are processed separately. The nonresponse adjustment factor for an individual is defined as the inverse response rate of the response homogeneity group (RHG) to which the individual belongs. RHGs are composed of all individuals with similar nonresponse characteristics. If the RHGs are defined so that nonresponse is completely random within each group, then the nonresponse bias is negligible (Tambay et al., 1998). To find an appropriate adjustment value to make respondent weights representative of all respondents and nonrespondents, we use nonresponse modelling.

[1] This category contains all longitudinal persons who are in the quality sample or in the same household as a member of the quality sample (there was one such person in the 1997 reference year).

The first step in nonresponse modelling is to determine which explanatory variables need to be in the model in order to correctly predict the dichotomous variable *response* (whose possible values are either *respondent* or *nonrespondent*). The simplest way of selecting these variables is to use information collected by the LFS, that is, prior to SLID's initial interviews. The advantage of this method is that the information is available for all longitudinal individuals, whether or not they are respondents in the current wave. However, some of the variables collected are subject to change (income, level of education, marital status, employment, presence of children, etc.) and may be outdated for the reference year of the wave being processed. Yet if we decided to use the most recent available information for each individual, we could end up with information from different reference periods (because of nonresponse in the wave being processed). In other words, for respondents, the information would be up-to-date, but for nonrespondents, older information would have to be used. Moreover, if the latest information were used for nonresponse modelling, the weight associated with the immediately preceding wave would have to be used as the base weight instead of SLID's initial weight. But that raises the problem of converted nonrespondents (persons who were respondents two waves ago, nonrespondents in the preceding wave and respondents in the current wave). Since converted nonrespondents have a longitudinal weight of zero in the wave preceding the current one, some way would have to be found to assign them a base weight. One way would be to use the weight computed two waves ago. In that case, it would be necessary to ensure that the method used to assign base weights from different periods was methodologically acceptable. The possibility of using the latest information for nonresponse modelling was also rejected because it was believed that the cumulative effect of all those nonresponse models would produce estimates that were too dependent on the nonresponse models.

SLID therefore elected to consider only known information gathered before the start of the first collection period. For Panel 1, this information was taken from the preliminary interview, since it was conducted at the time of the final LFS interview. For Panel 2, the information considered was collected at the final LFS interview.

The first step in nonresponse modelling (determining the explanatory variables) is not carried out until the first wave of a panel is processed, because the variables used in the nonresponse model must be determined at the outset. The variables selected for nonresponse modelling in the first wave are used in subsequent waves. To determine what explanatory variables should be used in the nonresponse modelling, categorical variables with $m>2$ possible values are recoded as m dichotomous variables. From all these variables, the ones most likely to affect response are selected subjectively.

Logistic regression is performed separately for each variable. On the basis of the results of these univariate regressions, the significant variables are selected. In all, 57 dichotomous variables were retained for Panel 1, and 43 for Panel 2. A complete list of the variables selected for each panel is provided in Appendix A. As mentioned earlier, the same variables are used for all waves of a panel; the only changes normally made are alterations in the possible values of some variables (e.g., age group and income bracket).

The second step is to generate the RHGs on the basis of the variables selected in the first step. Prior to the 1996 reference year, SLID created the RHGs by logistic regression: the SAS procedure LOGISTIC, with selection type STEPWISE, was used for this purpose. Since the 1996 reference year, SLID has been using segmentation modelling to generate the RHGs. The software package that applies this method is called KnowledgeSeeker (version 4.2.2). Segmentation modelling is preferred to logistic regression because it reduces nonresponse bias more effectively (Dufour et al., 1998).

Segmentation modelling employs an iterative process to partition the data file and form the decision tree. The root node of the tree is simply the entire data set. The first iteration defines the tree's first split. The latter is created by determining which of the variables selected for modelling has the most significant effect on the *response* variable. For each variable, a statistical measure reflecting the extent to which the variable discriminates nonresponse is computed, and the one that has the most significant effect is selected. This is how the first split is formed, with a node at each end. For each node formed, another iteration of the procedure is carried out. This in turn produces more splits and more nodes. When the process reaches a node where no variable has a significant effect on response, there are no further splits, and the formation of the branch is complete. The iterative process ends when all branches of the tree are completed.

A number of methods can be used to find the variable that has the greatest influence on the response variable. SLID uses chi-square automatic interaction detection (CHAID), an algorithm that selects the variable with the highest Pearson chi-square statistic.

One of the reasons segmentation modelling is preferable to logistic regression is that it is more flexible. Logistic regression forces the model to be symmetric: once the significant variables are determined, the RHGs are formed by taking all possible combinations of the intersection of these variables. This process can create small cells or cells that are not significant, which can affect the reliability of the estimates. Segmentation modelling allows the model to be asymmetric: at each split in the decision tree, it determines which variable is most significant. This ensures that each RHG is significant, and it usually results in an asymmetric model.

For example, in Panel 1 of SLID, the most significant variable in discriminating between response and nonresponse is a variable that indicates whether the person is a homeowner. For homeowners, the most significant variable in accounting for nonresponse is one that indicates whether a person was born in the United States, the United Kingdom or Canada. For non-homeowners, the next most significant variable in explaining nonresponse is one that indicates whether a person is over age 65 (see Figure 3.1 below).

Figure 3.1: First Few Branches of the Decision Tree for Panel 1, 1997 Reference Year

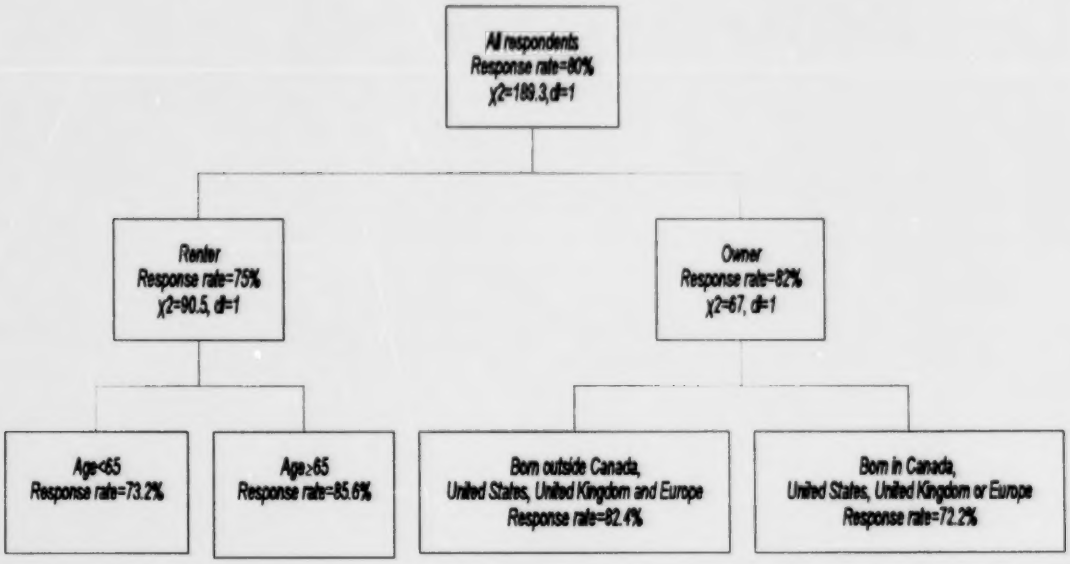

Another advantage of segmentation modelling is that it can be performed with the very user-friendly KnowledgeSeeker, a software package that simplifies the task of creating a decision tree. However, segmentation modelling also has a few drawbacks. While creating a decision tree is easy, the next step in the process is tedious and slow. The definitions of all the RHGs have to be coded into SLID's longitudinal weighting program so that each individual's nonresponse adjustment factor can be computed. Knowledge Seeker does not provide a file defining each RHG and the associated response rate.

Another drawback of segmentation modelling is directly related to the decision tree itself. Once formed, a decision tree can quickly become cumbersome; beyond a certain number of splits, it becomes difficult to interpret. Decision trees are also rather unstable: the addition, removal or alteration of one variable or one individual can have a major impact on the tree. This makes it very difficult to compare several decision trees.

In each wave, SLID generates a nonresponse adjustment model separately for each panel. Each model is initially defined at the national level. Province-level splits are kept in the decision tree if they are significant. SLID uses a national model because it is easier and more convenient than creating a model for each province. According to a 1999 study, the difference between using a national model and using provincial models is negligible. For further details on that study, see Franklin (1999a).

In accordance with the sampling design, the normed initial weights are used to compute a weighted chi-square statistic. It should be noted that SLID does not distinguish between the various types of nonresponse (attrition, not traced, refusal, etc.). Also important is the fact that some constraints are applied to the model during segmentation modelling: each RHG must contain at least 30 people (weighted and unweighted) and have a weighted response

rate of at least 50%. Kalton and Kasprzyk (1986) recommend these constraints because they prevent excessive variability in the weights and reduce loss of precision in the estimates.

Once the decision tree has been created, the RHGs are formed using the ends of the branches. The individuals used to model nonresponse (i.e., respondent adults and nonrespondent adults in nonrespondent households) and nonrespondent adults in respondent households are placed in the various RHGs. Note that even though nonrespondent adults in respondent households are deemed respondents, they are not used in nonresponse modelling because they did not actually respond to the survey.

The nonresponse adjustment is carried out within each RHG: the weights of the respondents in each RHG are divided by the RHG's weighted response rate (which is the same as multiplying the weights of the respondents by an adjustment factor equal to the inverse weighted response rate). For wave 5 of Panel 1, there were 282 RHGs, with an average weighted response rate of 84%. For wave 2 of Panel 2, there were 134 RHGs, with an average weighted response rate of 88%.

The nonresponse-adjusted weights are obtained by multiplying the initial weight of each respondent individual by the nonresponse adjustment factor (or dividing by the weighted response rate for the final RHG). The weights of nonrespondents are set to 0, and the initial weights of children and cross-sectionally out-of-scope individuals are left unadjusted.

In each wave, the nonresponse-adjusted longitudinal weights are derived as follows:

$$w_{adjust} = \begin{cases} 0, & \textit{for persons in non-respondent households} \\ w_{initial}, & \textit{for children or cross-sectionally out-of-scope persons} \\ \dfrac{w_{initial}}{R_{RHG}}, & \textit{for persons in respondent households} \end{cases}$$

where w_{adjust} = nonresponse-adjusted longitudinal weight
$w_{initial}$ = initial longitudinal weight (= $w_{initial,p_1}$ for Panel 1, $w_{initial,p_2}$ for Panel 2)
R_{RHG} = weighted response rate in the RHG

3.4 Adjustment for Influential Values

Once the weights have been adjusted to compensate for nonresponse, the next step is to identify influential values that have a major impact on cross-sectional income estimates and variance estimates. A value is considered influential if it has an excessive effect on the cross-sectional estimate of total provincial income. An adjustment factor between 0 and 1 is computed and applied to the weights of individuals identified as influential (and to the weights of the other members of the household) to reduce the influence their weights have on income estimates. There were no influential individuals in wave 5 of Panel 1, and only two influential individuals in wave 2 of Panel 2.

Only influential values affecting the cross-sectional estimates are identified in this way. The same procedure could be followed for influential values affecting longitudinal weights. This might result in adjustments that were different for longitudinal and cross-sectional weighting. However, tests for the 1995 reference year have shown that at that time, there would have been no difference in the individuals identified as influential and very little difference in the

adjustment factors. Consequently, the decision was made to use the cross-sectional adjustments for longitudinal weighting as well. For further details on the identification of influential values and the calculation of the adjustment factor, see subsection 4.6.

The longitudinal weight adjusted for influential values is defined as follows:

$$w_{infl} = w_{adjust} * \beta_{infl}$$

where w_{infl} = longitudinal weight after adjustment for influential values
w_{adjust} = nonresponse-adjusted longitudinal weight
β_{infl} = adjustment factor for influential values ($0 < \beta_{infl} \leq 1$).

3.5 Post-stratification

The purpose of post-stratification is to ensure that the sum of the weights within certain sample subgroups (post-strata) matches known control totals for the population of those post-strata for a given year. Post-stratification is carried out independently for the two panels. For each post-stratum, the sum of the weights prior to post-stratification is calculated, and the control total for the population is divided by that sum. Then the longitudinal weight following post-stratification is computed using the formula

$$w_{ps} = w_{infl} * \frac{T_L}{\sum_L w_{infl}}$$

where w_{ps} = longitudinal weight after post-stratification
w_{infl} = longitudinal weight adjusted for nonresponse and influential values
T_L = control total for post-stratum L

For the longitudinal weighting of SLID, the post-strata consist of province-sex-age group cross classifications. The age groups are shown in Table 3.2.

Table 3.2: Age Groups Used for Post-stratification

Age groups	
Panel 1 (8 age groups)	**Panel 2 (11 age groups)**
0-15	0-6
	7-15
16-19	16-18
20-24	19-24
25-34	25-34
35-44	35-44
45-54	45-54
55-64	55-59
	60-64
65+	65-69
	70+

For the 1996 reference year (Panel 2), substantial changes were made in the age groups used to process data. This was done to streamline the integration of SCF into SLID (cross-sectionally) and to comply with certain standards adopted by a number of major surveys at Statistics Canada. The new age groups went into effect in the 1996 reference year and were used for Panel 2 from the outset since it was selected in 1996. For Panel 1, the old age groups continued to be used for post-stratification to ensure stability and comparability of the various sets of weights produced during the waves prior to 1996.

The province used for longitudinal post-stratification is the one in which the individual lived at the time the sample for a given panel was selected, and the age group to which an individual belongs is determined by his or her age at the time the panel was selected. In addition, Panel 1's longitudinal weights after post-stratification must match the December 31, 1992, control totals for the Canadian population, while Panel 2's weights must match the December 31, 1995, control totals. The control totals are based on population projections generated by the Demography Division. The projections are only available in the middle of each month (and thus represent the population of Canada's ten provinces, with certain exclusions, at the middle of the month). SLID uses the projections for January.

The average post-stratification adjustment applied to longitudinal weights adjusted for nonresponse and influential values is 1.11 for wave 5 of Panel 1 and 1.10 for wave 2 of Panel 2.

3.6 Addition of Noise

At the time the longitudinal and cross-sectional weights for the 1997 reference year were computed, two public-use microdata files – a longitudinal file and a cross-sectional file – were produced each year. (As of the 1998 reference year, this is no longer done.) To

safeguard confidentiality, it is necessary to ensure that data in the two files cannot be used to reconstruct households. Despite the adjustments described in the preceding sections, it is possible for individuals from the same household to have the same weight, which can result in at least partial reconstruction of a household. To prevent this, a final step in the weighting process is carried out: noise is added to the weights on the public-use files. The magnitude of the noise added is determined from the distribution of differences between consecutive weights after they have been sorted in ascending order of magnitude.

There are several steps in the process of introducing noise into the post-stratified weights. First, all persons who are from the same original household and have the same weight, regardless of whether they still live together, are identified. Then they are grouped two by two. Where an odd number of persons in a household has the same weight, the weight of one person chosen at random is not altered. For each pair, a random value e is generated from a uniform distribution U(0,1) and added to the value a, determined as follows:

$$a = \frac{\max(w_{ps}) - \min(w_{ps})}{n}$$

where n is the sample size and $\max(w_{ps})$ and $\min(w_{ps})$ are computed for the Canada level. The value $e+a$, which falls between a and $a+1$, is then added to the weight of the first person in the pair and subtracted from the weight of the second. Thus, noise is added to the weights, and identical weights in the same household are eliminated. The control totals for each post-stratum are respected since individuals from the same household who have the same weight before the addition of noise necessarily come from the same post-stratum and thus have the same adjustments for nonresponse, influential values and post-stratification.

The weight following noise addition, known as the external weight, is obtained as follows:

$$w_{noise} = \begin{cases} w_{ps} \pm (e+a), & \textit{for pairs of individuals in the same household whose weights are identical} \\ w_{ps}, & \textit{in all other cases} \end{cases}$$

where
- w_{noise} = longitudinal weight after noise addition
- w_{ps} = longitudinal weight after post-stratification
- e = random noise
- a = longitudinal noise

The value of a for the 1995 and 1996 reference years (1.25) was also used for the 1997 reference year (both panels). For more details, see Franklin and Lévesque (1999).

3.7 Description of the Final Longitudinal Weights

Two sets of longitudinal weights are produced: a set of internal weights and a set of external weights. The internal weights, whose production is complete at the end of subsection 3.5 above, are used in studies conducted within Statistics Canada; no noise has been added to them. Noise is only added to the external weights, which are intended for users outside Statistics Canada. These are the weights whose production is complete at the end of subsection 3.6.

Table 3.3 shows the median initial and final longitudinal weights by province for the 1997 reference year. Only individuals with non-zero final weights are included in the calculation of the medians. The weights considered here are internal weights (i.e., no noise added). The province is the individual's province of origin (i.e., the province in which the individual was living when the sample for the panel to which he belongs was selected).

Table 3.3: Median Internal Longitudinal Weights (Initial and Final), for Wave 5 of Panel 1 and Wave 2 of Panel 2

Province	Panel 1		Panel 2	
	Initial weights	Final weights	Initial weights	Final weights
Newfoundland	207	250	242	285
Prince Edward Island	138	164	95	107
Nova Scotia	237	305	281	322
New Brunswick	279	321	254	296
Quebec	565	699	566	676
Ontario	563	769	558	718
Manitoba	221	309	327	409
Saskatchewan	305	370	279	347
Alberta	783	870	693	967
British Columbia	661	848	811	1117

4. Cross-sectional Weighting

This section provides a detailed description of the steps required to create a set of weights representative of Canada's ten provinces on December 31 of a given reference year. All cross-sectionally in-scope longitudinal individuals and their cohabitants are included in the production of this set of weights. The methodology described here is the one used for the 1997 reference year.

SLID produces various sets of cross-sectional weights. These sets are composed of individual or integrated weights. While each member of a household may have a different individual weight, every member of that household has the same integrated weight. Integrated weights are suitable for household-level studies, but they can also be used for studies at the person level. Individual weights, on the other hand, can only be used at the person level. Some sets of weights are produced exclusively for use within Statistics Canada (internal weights), while others are produced for users outside the Agency (external weights). For the sake of confidentiality, noise is added to all external weights. In producing cross-sectional weights for the 1997 reference year, it was important to ensure that the public-use microdata files to be produced could not be used to reconstruct households (to safeguard confidentiality). For that reason, integrated weights are available only within Statistics Canada. For studies conducted outside the Agency, individual weights must be used.

In all, four sets of cross-sectional weights are produced. The first set consists of *integrated weights*, which, as noted above, are internal weights. The second set is composed of *usual external individual weights*. The third set is made up of *internal labour weights*. The latter are individual weights similar to usual individual weights, except that the concept of respondent used in producing them is somewhat different. Respondent identification is based on the labour interview alone rather than both the labour and income interviews. For example, a household that is nonrespondent at the labour interview (i.e., all members of the household are nonrespondents at that interview) but respondent at the income interview (because the members preauthorized access to their tax data) will be included in the usual individual weighting but not in the labour weighting. Using labour weights rather than integrated weights or usual individual weights provides a better estimate of labour characteristics. The fourth set of weights consists of *external labour weights*.

The cross-sectional weighting process involves the following eight steps: determination of individuals eligible for cross-sectional weighting (subsection 4.1), nonresponse adjustment (4.2), application of panel allocation factors (4.3), weight share (4.4), interprovincial migration adjustment (4.5), adjustment for influential values (4.6), post-stratification (4.7) and addition of noise (4.8). The final cross-sectional weights are described in subsection 4.9.

4.1 Determination of Individuals who are Eligible for Cross-sectional Weighting

The cross-sectional sample for a given year is representative of the population of Canada's ten provinces on December 31 of the reference year (except for households composed entirely of immigrants). It consists of longitudinal individuals who are still members of the population of Canada's ten provinces as of December 31 of the reference year, plus their cohabitants. These individuals are considered to be *cross-sectionally eligible*.

Before we can determine which individuals have a non-zero cross-sectional weight, we must first identify those who are cross-sectionally eligible (in scope). All longitudinal individuals who are no longer members of the target population on December 31 of the reference year (e.g., persons who have moved to a place outside the ten Canadian provinces, deceased

persons, and persons living in an institution) are assigned a cross-sectional weight of zero, even if they are respondent (or deemed respondent). Of the longitudinal individuals who belong to the target population on December 31 of the reference year, only those who are members of respondent households have non-zero cross-sectional weights. For the purposes of producing usual individual weights and integrated weights, a household is defined as respondent if at least one member responded in at least one of the two interviews (the labour interview or the income interview). Information about nonrespondent persons in respondent households will be imputed. For the purposes of labour weights, a household is respondent if at least one member responded in the labour interview.

4.2 Nonresponse Adjustment

As noted above, the cross-sectional sample for a given year is representative of the population of Canada's ten provinces on December 31 of the reference year. Like any other survey, however, SLID is subject to nonresponse (in this case, we are referring to total nonresponse), which affects the representativeness of the sample. To mitigate the effects of nonresponse bias, we adjust the weights of respondents to compensate for nonrespondents.

From a cross-sectional standpoint, we have too little information about nonrespondent cohabitants to adjust for nonresponse at that level. For many cohabitants, the only available variables are province, age and sex, which in any case will be used in the post-stratification step. To circumvent this problem, two methods of cross-sectional nonresponse adjustment have been proposed (Latouche, Michaud, 1997). One solution is first to make a nonresponse adjustment for longitudinal individuals only and then to use the weight share method to assign a weight to cohabitants. The weights of cohabitants are thus indirectly adjusted for nonresponse. The other method is to adjust for nonresponse at the household level using the initial dwelling strata and rotation groups of the LFS sample design. However, household-level adjustment tends to underestimate the response rates slightly.

SLID adopted the first method described above. Consequently, the cross-sectional nonresponse adjustment step is not related to cross-sectional weighting but to longitudinal weighting. Longitudinal nonresponse modelling and adjustment were described in subsection 3.3 above. As indicated there, for longitudinal weighting each panel is treated separately. The cross-sectional weight adjusted for longitudinal nonresponse is therefore equal to the weight w_{adjust} derived in subsection 3.3. We denote the cross-sectional weight adjusted for longitudinal nonresponse as $w_{1997,adjust}$. This weight is used as the initial weight for the production of all derived cross-sectional weights (usual individual weight, integrated weight and labour weight).

4.3 Application of Panel Allocation Factors

The 1996 reference year was the first year for which SLID had overlapping panels. In theory, the two panels could be used independently of one another to produce cross-sectional estimates, but in practice, it is better to combine the two cross-sectional samples to produce the cross-sectional estimates. This doubles the sample size, which in turn reduces the variability of the estimates and permits the use of more control totals in the post-stratification step.

Since the two longitudinal samples are representative of the population of Canada's ten provinces at different reference periods (December 31, 1992, for Panel 1, and December 31, 1995, for Panel 2), a way has to be found to combine the two samples so that they both

represent the target population for a given reference year. The problem that arises is the time lapse between them. Figure 4.1 shows how the population of the ten provinces changed between the selection of Panel 1 and the selection of Panel 2.

Figure 4.1: Change in the Population of Canada's Ten Provinces Between the Selection Dates of the Two Panels

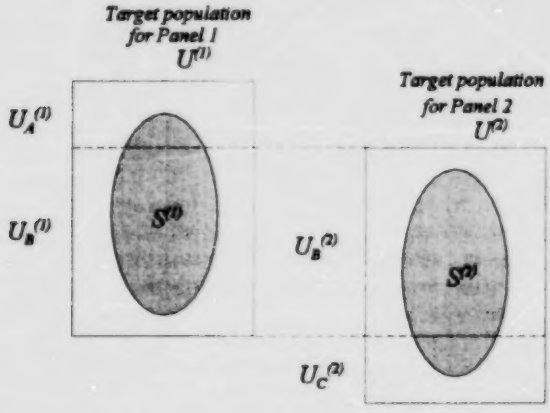

Sample $S^{(1)}$ was selected from the population of Canada's ten provinces $U^{(1)}$ in January 1993. (This was the longitudinal sample for Panel 1.) Sample $S^{(2)}$ was selected from the population of Canada's ten provinces $U^{(2)}$ in January 1996 to form the longitudinal sample of Panel 2. Most individuals present in the January 1993 population are also present in the January 1996 population ($U_B^{(1)} = U_B^{(2)}$). The differences between populations $U^{(1)}$ and $U^{(2)}$ are due to departures from the target population between January 1993 and January 1996 (deaths, persons placed in institutions, persons who moved to places outside the provinces, etc.) and to additions to the population after January 1993 (immigrants, births). Part of the Panel 1 sample is composed of persons who left the population between January 1993 and January 1996 ($U_A^{(1)}$); since those individuals were no longer members of the Canadian population when the sample for Panel 2 was selected, they had no chance of being selected. Conversely, part of the Panel 2 sample is made up of persons who were in the population of Canada's ten provinces when that sample was selected but were not in the population when Panel 1 was selected ($U_C^{(2)}$); those persons had no chance of being selected for Panel 1.

To develop a method of combining the information from the cross-sectional samples of the two panels, we need only consider the two panels at the time Panel 2 was introduced. The population of interest is $U^{(2)}$, the target population at the time Panel 2 was introduced. The longitudinal samples of interest are the original samples selected, with the Panel 1 sample having been reduced by population departures and nonrespondents. SLID uses Merkouris's method (1999) to match overlapping samples (in this case, the samples for Panels 1 and 2). If Y is a population parameter, we can use the following combined estimator (which assigns a relative importance to each panel based on a certain factor p):

$$\hat{Y} = p\hat{Y}_1 + (1-p)\hat{Y}_2$$

where $\hat{Y}$ is the cross-sectional estimate for a variable of interest, $\hat{Y}_i$ is the estimate produced for that variable for Panel i, and p is the panel allocation factor. This estimator can be regarded as a weighted sum of the estimators of the two panels, where the weights are the panel allocation factors. The optimum value of the panel allocation factor was set so as to minimize the variance of $\hat{Y}$. The panel allocation factor is defined as follows:

$$p = \left(\frac{n_1}{d_1}\right)\left(\frac{n_1}{d_1} + \frac{n_2}{d_2}\right)^{-1} = \frac{n_1}{n_1 + n_2\left(\frac{d_1}{d_2}\right)} \qquad (4.1)$$

where d_i denotes the design effect for Panel i and n_i represents the number of Panel i longitudinal persons aged 16 and over who were respondent at time t (where t is the reference year concerned, which in this case is 1997). The design effect is defined as the ratio of the variance of the subweighted estimate (i.e. without benchmarking to population control totals) to the variance associated with a simple random sample of the same size. For SLID, the number of longitudinal persons aged 16 and over who were respondent at time t is the same as the number of cross-sectionally in-scope longitudinal persons aged 16 and over who are in a respondent household (since all members of respondent households are deemed respondent (see subsection 3.2)). Even though cohabitants are used to produce the cross-sectional estimates, only longitudinal persons respondent at time t are considered in computing the panel allocation factors. Merkouris (1999) and Lavallée (1994) suggest combining the two panels before incorporating cohabitants by the weight share method. Leaving cohabitants out of the computation of factor p helps to reduce the importance of the older panel and thus to minimize the potential effects of attrition bias.

To determine the optimum factor p, we need to estimate the design effects and the longitudinal sample sizes. However, no design effect was available for Panel 2 at the time of data processing. Since SLID is a subsample of the LFS, it was decided to use LFS data to derive the design effects needed to compute the p factors. Moreover, since we are interested in the ratio of two design effects, the LFS is a perfectly legitimate source for the required effects. The LFS's six rotation groups are used to determine the design effects. The effects are calculated for the *number of persons aged 15 and over* characteristic at the provincial level (which will require the calculation of ten panel allocation factors, one per province). For Panels 1 and 2 combined, the LFS files for January 1993 and January 1996 were used to compute the design effects. The required sample sizes were computed from the longitudinal samples of the two panels for the reference year concerned. As noted above, the sample sizes are the number of longitudinal persons aged 16 and over who were respondent at time t. They are obtained by counting all cross-sectionally in-scope persons aged 16 and over in respondent households.

Once the design effects and the sample sizes are known, it is easy to compute the panel allocation factors using equation 4.1. The factors must be calculated for each year involved since the composition of the longitudinal samples changes each year. For practical reasons, it was decided to compute the design effects at the inception of each new panel and to use those design effects in calculating the panel allocation factors for the three overlap years (Latouche et al., 2000). The panel allocation factors for the 1997 reference year are presented in Table 4.1 below.

Table 4.1: Panel Allocation Factors for the 1997 Reference Year

Province	d_1/d_2	n_1	n_2	p (Panel 1)	$1-p$ (Panel 2)
Newfoundland	1.71	1693	1306	0.4312	0.5688
Prince Edward Island	1.92	568	883	0.25095	0.74905
Nova Scotia	4.02	1788	1986	0.18298	0.81702
New Brunswick	1.94	1752	1819	0.33176	0.66824
Quebec	2.75	4908	5788	0.23568	0.76432
Ontario	2.87	6893	8901	0.21249	0.78751
Manitoba	1.36	1776	2111	0.38219	0.61781
Saskatchewan	2.21	1915	1872	0.31642	0.68358
Alberta	2.87	2378	2113	0.28168	0.71832
British Columbia	2.76	2238	2509	0.24425	0.75575

d_i = design effect for Panel i
n_i = number of Panel i respondent longitudinal persons aged 16 and over for the 1997 reference year
p, 1 - p = panel allocation factors

The table shows that the factors favour Panel 2 by a ratio of 3 to 1. In the most recent postcensal redesign of the LFS (completed in late 1994), its sample design was improved; as a result, the ratio d_1 / d_2 is high, which gives Panel 2 greater importance. When Panels 2 and 3 of SLID are combined, the ratio of the design effects will be closer to 1 since both panels will have been selected from the same LFS sample design. The panel allocation factors will be closer to 0.5, and the two panels will have similar importance.

The *p* factors are applied to all Panel 1 longitudinal persons who were in a respondent household at time t (in this case, December 31, 1997). The *1-p* factors should be applied to all Panel 2 longitudinal persons who were in a respondent household at time t, except persons who were outside the target population when Panel 1 was introduced (January 1993) and in the target population when Panel 2 was introduced (January 1996). For practical reasons, only newborns and immigrants who were not present when Panel 1 was introduced but were present when Panel 2 was introduced are exempted from application of the *1-p* factors. Those excluded will retain their weights as adjusted for longitudinal nonresponse. Accordingly, the cross-sectional weight adjusted for the combination of the two panels is as follows:

$$w_{1997,p} = \begin{cases} p\, w_{1997,adjust}, & \text{for Panel 1 persons} \\ (1-p)\, w_{1997,adjust}, & \text{for Panel 2 persons not exempted from application of the panel allocation factors} \\ w_{1997,adjust}, & \text{for Panel 2 persons exempted from application of the panel allocation factors} \end{cases}$$

where $w_{1997,p}$ = cross-sectional weight adjusted for the combination of the two panels
$w_{1997,adjust}$ = cross-sectional weight adjusted for longitudinal nonresponse
p = panel allocation factor

This weight is identical for the usual individual and integrated cross-sectional weights. For the labour cross-sectional weight, the weight adjusted for the combination of the panels is computed in the same way, but the definition of respondent household is different (subsection 4.1). Note that the panel allocation factors are applied to the weights after the nonresponse adjustment step and before the weight share step, so that they will be included in the weights of cohabitants.

4.4 Weight Share

The weight share step is essential and unique to cross-sectional weighting. It is necessitated by the longitudinal nature of SLID. In a longitudinal survey, the sample evolves over time. New people move in with the selected individuals, and children are born into some of the sample households. In short, persons who were not originally selected become part of the sample. Since we do not have any probability of selection for these new persons (cohabitants), we have to find a way to assign them a weight. This is done by the weight share method. A brief explanation of this method is presented below. For further details, the reader should refer to the article by Lavallée (1995).

From the weight share step onward, no distinction is made between the two panels, and all individuals are treated as part of same sample, though the concepts of longitudinal individual and cohabitant remain. One might think that since we choose to perform the weight share at the household level, there would be no difference between treating the two cross-sectional samples separately or together. It is important to keep in mind that in a survey with multiple overlapping panels, some households may contain persons from Panel 1 and persons from Panel 2. When the longitudinal sample for Panel 2 was selected, any household containing at least one longitudinal person from Panel 1 was excluded in order to avoid surveying the same household for another six years. Because of the survey's dynamic, longitudinal nature, however, over a six-year period households may break up and new households may form. As a result, there is a possibility that the survey will include households with members from the two panels. If the cross-sectional samples are considered separately, two distinct sets of weights would be produced for such households, and this would cause all sorts of problems. For this reason, it is better to consider the two panels together.

It must first be determined at what level in the sample design hierarchy the weight share is to be performed: province, stratum, primary sampling unit or final sampling unit. SLID elected to perform the weight share at the level of the final sampling unit, the household. Once that decision is made, it is necessary to determine the status of each person in the cross-sectional sample: longitudinal individual, initially present cohabitant or initially absent cohabitant.

A cohabitant is initially present if he or she was a member of the target population when Panel 2 was selected (January 1996). Conversely, a cohabitant is initially absent if he or she was not a member of the target population when Panel 2 was selected (January 1996). Now these concepts – initially absent and initially present cohabitant – must reflect the fact that there are two overlapping panels in the survey and that these panels must be considered together at the time of Panel 2's selection (January 1996). It is important to note that all cohabitants have a longitudinal weight of zero since they are not part of the longitudinal

sample. They may, however, have a non-zero cross-sectional weight, assigned by the weight share method.

In the weight share step, two different weights are produced for each individual: an individual weight (which may be different for each member of a given household) and an integrated weight (which is the same for all members of a given household).

In the case of the weight share for individual weights, the following steps are required. First, the households to which cohabitants have moved since the longitudinal sample was selected must be identified. For households composed entirely of longitudinal persons, the weight share method is not needed. For all members of such households, the shared cross-sectional weight is identical to the adjusted cross-sectional weight after the panel allocation factors are applied.

Second, for households with new cohabitants, the nonresponse-adjusted cross-sectional weights $w_{1997,p}$ of all longitudinal household members must be added together. Then the longitudinal individuals and the initially present cohabitants must be counted.

For households with at least one cohabitant initially present, the shared cross-sectional weight of all members is the sum of the cross-sectional weights $w_{1997,p}$ of all longitudinal members divided by the total number of longitudinal individuals and initially present cohabitants in the household.

For households with all cohabitants initially absent, the shared cross-sectional weight of longitudinal individuals and cohabitants is calculated in a different way. For longitudinal members of such households, the shared cross-sectional weight is equal to the adjusted cross-sectional weight following application of the panel allocation factors. For cohabitants, the shared cross-sectional weight is equal to the sum of the weights $w_{1997,p}$ of all longitudinal members divided by the total number of longitudinal members. Thus, the longitudinal individuals will not be assigned an average weight, and the nonresponse adjustment will be preserved. Only initially absent individuals will be assigned the average weight of the household's longitudinal members.

The shared individual cross-sectional weight (usual individual weight or labour weight) is defined as follows:

$$w_{1997,shared} = \begin{cases} w_{1997,p}, & \text{for persons in households composed entirely of longitudinal persons and for longitudinal members of households in which all cohabitants are } IA \\ \dfrac{\sum_h w_{1997,p}}{n_{L,h} + n_{IP,h}}, & \text{for persons in households with at least one cohabitant } IP \\ & \text{and for cohabitants in households where all cohabitants are } IA \end{cases}$$

where $w_{1997,shared}$ = shared cross-sectional weight
$w_{1997,p}$ = cross-sectional weight adjusted for the combination of the two panels
IP = initially present
IA = initially absent
$n_{L,h}$ = number of longitudinal persons in household h
$n_{IP,h}$ = number of cohabitants initially present in household h

In the case of the weight share for integrated weights, the process is somewhat different. Every individual with a non-zero individual cross-sectional weight (usual individual weight only) also has a non-zero integrated cross-sectional weight. This is necessary because the weight prior to post-stratification must be identical for all members of a household so that an integrated weight can be produced (Lemaître, Dufour, 1987). The difference between integrated weights and individual weights derives from the fact that weight share has to be performed for all households, whether they contain cohabitants or not. Consequently, for all households the shared weight is computed in the same way for all individuals when the weight produced is integrated. The integrated shared cross-sectional weight is therefore defined as follows:

$$w_{1997,shared} = \frac{\sum_{h} w_{1997,p}}{n_{L,h} + n_{IP,h}}$$

where $w_{1997,shared}$ = shared cross-sectional weight
$w_{1997,p}$ = adjusted cross-sectional weight after combination of the two panels
$n_{L,h}$ = number of longitudinal persons in household h
$n_{IP,h}$ = number of cohabitants initially present in household h

For the 1997 reference year, there were 80,834 persons in the cross-sectional sample. This total includes respondent and nonrespondent persons (for nonrespondent households, the last known household composition is used). It understates the actual number of persons in the cross-sectional sample because there is no information about the current composition of nonrespondent households. Of the 80,834 persons, 79,218 have non-zero usual individual and integrated cross-sectional weights, and 76,421 have non-zero labour cross-sectional weights.

4.5 Adjustment for Interprovincial Migration

Like the weight share step, the interprovincial migration adjustment step is directly related to the longitudinal nature of SLID. Over time, some people in the sample move from one province to another. Since the probability of selection can vary widely with geographical location, there is a substantial difference at the national level between the largest weights and the smallest ones. As a result, if a person with a fairly low selection probability (and therefore a fairly large weight) moves to a location where a given individual's selection probability is much higher (and that individual's weight is much smaller), problems can arise. In particular, certain cases of interprovincial migration can distort the results of analytical studies.

A simple example will help explain the problem. Suppose a heart surgeon moves from Toronto to Charlottetown. This would cause several difficulties. First, the surgeon's weight of about 400 would be much larger than any of the weights in Prince Edward Island, which average close to 65. The surgeon alone would immediately represent approximately 3.33% of the province's population, or about 5,000 people out of 150,000, which is completely unacceptable. Furthermore, from an analytic standpoint, he would artificially inflate the population's total income because of his weight of 5,000 and his salary.

A number of options are available to alleviate the problem of outlier weights due to interprovincial migration. Such weights could be replaced with the average weight, the

median weight, a quantile of the weight distribution of in the province of destination, or some other value based on that distribution. The alternatives are arbitrary, and any of them could be used. What is needed is a compromise between assigning the migrant a weight similar to the average weight in the province of destination and excessively altering the migrant's original weight (based on selection probability). We must first identify those persons who have migrated to other provinces and whose weights are causing an imbalance in the estimates for their provinces of destination, and then adjust the weights.

The method adopted by SLID uses the 95th percentile of the distribution of weights. This is a quick, simple method that requires little or no manual intervention. First it is necessary to identify every person who has moved to another province and whose weight is larger than the largest weight of the province's current population. The weights of such persons are then set to the 95th percentile of the province's weight distribution. Next, a random number between 0.00 and 10.00 is subtracted from that percentile to ensure that the weights remain nearly unique (two people can have the same individual weight, but such cases are very rare).

Interprovincial migration adjustments are made independently for individual and integrated weights and are recalculated each year. Integrated weights are adjusted at the household level to keep the weights in a household equal. The cross-sectional weight adjusted for interprovincial migration is defined as follows:

$$w_{1997,mig} = w_{1997,shared} * a_{mig}$$

where $w_{1997,mig}$ = cross-sectional weight adjusted for interprovincial migration
$w_{1997,shared}$ = shared cross-sectional weight
a_{mig} = interprovincial migration adjustment factor

For the 1997 reference year, an interprovincial migration adjustment was required for the usual individual cross-sectional weights of 36 persons, for the integrated cross-sectional weights of 15 households (43 persons), and for the labour cross-sectional weights of 34 persons.

4.6 Adjustment for Influential Values

Like any survey that attempts to estimate income distribution, SLID is very likely to face the problem of influential values (such distributions have very long tails). Influential values have a significant impact on provincial estimates of total and average income and their variance estimates. The impact is even greater on estimates for smaller domains such as age group, sex or family size. Hence, methods must be developed to identify the influential values and then adjust them so as to reduce the effect they have on estimates.

The process of identifying influential values and calculating adjustment factors applies only to individual weights (usual individual weights or labour weights), while the adjustment factors produced are used on both individual and integrated weights.

SCF devised a method of detecting and processing influential values (Tremblay, 1998). Since it was known that SCF would be incorporated into SLID for the 1999 collection period, the methodology takes into account the fact that the successor survey is longitudinal.

Accordingly, SLID adopted this approach to deal with the problem of influential incomes. The first step is to identify the influential items, that is, observations that contribute too heavily to the weighted estimate of total personal income for the province. Such observations usually occur in upper income brackets. An individual's income (in this case, total income less capital gains) is regarded as influential if the contribution of the individual's weighted income to the provincial weighted estimate exceeds a certain threshold. This threshold is equal to the lower limit of the interval computed by the quartile method. It is defined as MED + k (Q3 - MED), where MED and Q3 are the median and the third quartile, respectively, of the weighted contribution of individuals, and k is a fixed parameter for each province, determined following a review of the highest percentages of contribution to the provincial estimate. (The value of k is 75 for Quebec and Ontario and 25 for all other provinces.)

Having identified the influential values, we must now compute the adjustment factors for their weights. To do so, we determine whether incomes over $99,999 are overrepresented in the sample compared with the distribution of taxfiler incomes from Revenue Canada's T1 file. If so, the weight is adjusted so that the distribution of the weighted sample matches that of the tax data (in order to keep weight adjustments to a minimum, this adjustment is not made in cases where the difference between the two distributions is small). The adjustment is made with an adjustment factor whose value is between 0 and 1. A separate adjustment factor is computed for each individual with an influential income, as described below. Note that the calculations are done at the provincial level.

> [Translation]
> *If a province has more than one influential person, the adjustment factor is computed first for the influential person with the highest income (unweighted). Suppose the person is in income class c. The adjustment will ensure that the estimate of the number of persons in class c or any higher income class is equal to the number of persons in the same income classes based on tax data, subject to certain constraints. First, only the weights of influential persons will be changed by this adjustment. In addition, if the adjustment increases the weight, i.e., the adjustment factor is greater than 1, the adjustment will not be applied and the initial weight will be retained. If the tax file shows that there is no one in the income classes, the adjustment will lower the weight to 1. Similarly, the weight will be reduced to 1 if the estimated number of persons in these classes based on non-influential persons only is greater than the number of persons according to the tax file.* (Tremblay, 1998).

Calculation of the adjustment factor carries over from one individual to the next. When the adjustment factor has been computed for the influential individual with the highest income, that individual's adjusted weight is considered in computing the adjustment factor for the next individual.

Although the adjustment factor is calculated at the person level, it has to be applied to the weights of the influential individual and all other members of the same household, for the duration of panel even if the person is no longer considered influential in waves following the one in which he or she was identified. The longitudinal nature of the survey makes this procedure necessary in order to maintain consistency over time, even with respect to cross-sectional weighting. For households in which no individuals are identified as having extreme income values, the adjustment factor is 1 for all household members.

To detect influential values, the method employs the weight obtained after post-stratification (to be discussed in the next subsection) since the latter is based on income distribution.

Hence, temporary post-stratification must be carried out before the adjustment for influential values so that the temporary post-stratified weights can be used to identify and process the influential values. Once the adjustment factors have been computed, post-stratification must be redone; the factors are applied to the weights that we had before the temporary post-stratification (that is, to the cross-sectional weights adjusted for interprovincial migration $w_{1997,mig}$).

The cross-sectional weight adjusted for influential values is computed as follows:

$$w_{1997,infl} = w_{1997,mig} * ß_{infl}$$

where $w_{1997,infl}$ = cross-sectional weight adjusted for influential values
$w_{1997,mig}$ = cross-sectional weight adjusted for interprovincial migration
$ß_{infl}$ = adjustment factor for influential values

For the 1997 reference year, two individuals were identified as having influential incomes. In addition, the weights of seven other persons identified as influential in previous waves had to be adjusted again. When other members of the households are counted, the adjustment was applied to a total of 29 people for the 1997 reference year. The adjustment factors ranged from 0.39 to 0.93, and most of them were in the vicinity of 0.50.

4.7 Post-stratification

As noted earlier, the purpose of post-stratification is to ensure that the sum of the weights in certain sample subgroups (post-strata) match the known control totals for the population of the post-strata for a given year.

For individual cross-sectional weights, post-stratification is carried out in the same way as in the longitudinal weighting process (subsection 3.5). The weight after post-stratification is equal to the weight before post-stratification multiplied by the control total for the population of the post-stratum to which the individual belongs, divided by the sum of the post-stratum's weights before post-stratification.

The method for producing the integrated weight is slightly more complex. Aside from matching the control totals for each post-stratum, post-stratification must also ensure that all individuals in the same household have the same final weight. For further information on how this is done, see the article by Lemaître and Dufour (1987). Let $w_{1997,ps}$ be the cross-sectional weight after post-stratification.

Like the post-strata for longitudinal weighting, the post-strata for cross-sectional weighting are province-sex-age group cross classifications. Province here refers to province of residence on December 31 of the reference year. Similarly, the age group to which an individual belongs is determined by his or her age on December 31 of the reference year. The age groups are those presented earlier in Table 3.2.

For the 1997 reference year, the usual individual weights adjusted for influential values were multiplied by an average of 1.13 to calibrate SLID sample. The integrated cross-sectional weights were also multiplied by an average of 1.13 during post-stratification. The average adjustment made to labour cross-sectional weights to calibrate the sample was 1.18.

4.8 Addition of Noise

As in the case of longitudinal weights, noise is added to the cross-sectional weights to preserve confidentiality. Note that noise addition applies only to individual cross-sectional weights and not to integrated weights. The reason for this is that releasing integrated weights in public-use microdata files would conflict with the aim of preventing reconstruction of households with the microdata. Consequently, only individual weights are included in the public-use files and therefore require the addition of noise.

The procedure for adding noise to individual cross-sectional weights is the same as for longitudinal weights (see subsection 3.6). The random noise e, with a value between 0 and 1, and the cross-sectional noise a, both of which are added to the individual cross-sectional weights, are calculated in the same way as they are in longitudinal weighting. The noise-added individual cross-sectional weights are obtained as follows:

$$w_{noise} = \begin{cases} w_{ps} \pm (e + a), & \textit{for pairs of individuals in the same household whose weights are identical} \\ w_{ps}, & \textit{in all other cases} \end{cases}$$

where w_{noise} = cross-sectional weight after noise addition
w_{ps} = cross-sectional weight after post-stratification
e = random noise
a = cross-sectional noise

The value of a for the 1995 and 1996 reference years (1) was also used for the usual individual weights in the 1997 reference year. The value of a for the labour weights was 1.25.

4.9 Description of the Final Cross-sectional Weights

Cross-sectional weighting produces four different sets of cross-sectional weights: integrated weights, usual external individual weights, internal labour weights and external labour weights. The integrated weights and internal labour weights are final at the end of the post-stratification step (subsection 4.7), while the usual external individual weights and the external labour weights are final after the noise addition step (subsection 4.8). Table 4.2 presents the medians of the initial cross-sectional weights and of selected final cross-sectional weights for the 1997 reference year. Only individuals with non-zero final weights are used in computing these medians. The province indicated in the table refers to the province of residence on December 31, 1997.

Table 4.2: Median Initial and Final Cross-sectional Weights, 1997 Reference Year

Province	Initial weight	Final weights		
		Integrated weight	Usual external individual weight	Internal labour weight
Newfoundland	133	127	129	133
Prince Edward Island	71	71	75	77
Nova Scotia	105	113	113	117
New Brunswick	150	150	155	159
Quebec	270	309	309	318
Ontario	253	301	302	314
Manitoba	148	167	171	180
Saskatchewan	161	163	165	170
Alberta	261	303	302	316
British Columbia	305	421	411	426

5. Forthcoming Changes and Future Developments

To improve the quality and reliability of the estimates, SLID's longitudinal and cross-sectional weighting processes are revised regularly. In particular, the revisions take into account any changes in the survey's objectives, processing and dissemination.

One such change relates to SLID's microdata dissemination strategy. Before SCF was incorporated into SLID (the merger came after the 1997 reference year), the dissemination strategy consisted in the annual production of a set of public-use longitudinal and cross-sectional microdata files that cannot be used to reconstruct households. Now that SCF has been integrated with SLID, producing cross-sectional files that will satisfy the needs of SCF users has become a priority. To that end, the content of the public-use cross-sectional files must be redefined and must include identifiers that can be used to reconstruct households and families.

The dissemination of such cross-sectional files raises doubts about the dissemination of public-use longitudinal files. The risk of disclosure associated with longitudinal files (i.e., that they could be used to reconstruct households and families) would probably be too high, and it would probably be difficult to produce longitudinal files that would have a low potential for matching with cross-sectional files. In view of these priorities, SLID has decided to focus on the dissemination of cross-sectional microdata and to explore other options for making longitudinal data available to users outside Statistics Canada. Two possibilities are remote access to data and the research data centre. For more information about the disclosure control strategy, see the article by Nadeau, Gagnon and Latouche (1999).

Since the dissemination of a public-use longitudinal microdata file looks very unlikely, it no longer seems necessary to produce external longitudinal weights. In addition, since the new dissemination strategy allows for the construction of households and families from cross-sectional data, external individual cross-sectional weights are no longer needed. For the moment, the two sets of weights are still being produced, but the possibility of discontinuing them will be discussed in the near future.

Another change in the survey will be the introduction of labour data imputation primarily for persons who are nonrespondent in the labour interview but respondent in the income interview. Before SCF was merged with SLID, records in the public-use files were allowed to have missing labour characteristics. Now that the two surveys have been combined, we wish to publish complete files with no missing data. Consequently, the labour weights are of questionable value. Since imputation will be used in cases of nonresponse in the labour interview, it seems pointless to continue producing labour weights that compensate for nonresponse by including only labour interview respondents in the weighting process. Labour weights are still being produced, but more serious consideration will be given to discontinuing them once all the labour data imputation procedures are in place.

There are also plans to change the calibration of the cross-sectional sample. SLID is currently revising its calibration strategy in order to improve the estimates and harmonize concepts across the various household surveys. Up to now, SLID has used province-sex-age group control totals to calibrate its cross-sectional sample. Additional sets of control totals are planned: number of economic families of size 1, 2 and 3 or more by province, and income level (low, middle, high) by province.

The introduction of these new control totals raises questions about the definition of the sets of control totals used so far, especially the age-group totals. It has also led to a change in the method of calibrating the sample: post-stratification is to be replaced by a raking ratio method. SLID's methodology team is currently reviewing its strategy for smoothly

incorporating these new totals into the existing calibration method. The impact that this change will have on the weights will also be studied thoroughly.

In the area of longitudinal weighting, plans call for the production of weights that will reflect both SLID panels. The challenge will be to define the longitudinal population for more than one panel. At present, longitudinal weighting treats the two panels separately, producing weights for each panel independently. Computing longitudinal weights with the respondents of both panels would increase the precision of the estimates for the purposes of longitudinal studies (since the sample size would be doubled). The method used to produce such weights would be based on the method used to combine SLID's cross-sectional samples.

6. Conclusion

SLID's goal – to provide longitudinal and cross-sectional data representative of the population of Canada's ten provinces for various characteristics related to labour and income dynamics – is a formidable challenge. The required longitudinal and cross-sectional weights are produced by the weighting processes described in detail in this document. A number of steps must be carried out to produce those weights: determination of initial weights, nonresponse adjustment, weight share (for cross-sectional weights only), interprovincial migration adjustment (for cross-sectional weights only), adjustment for influential values, post-stratification and addition of noise. These steps have been improved and optimized over the years, but as processing and dissemination strategies evolve, further refinements are needed, in particular to maintain data quality and reliability. These refinements include the introduction of new post-strata for cross-sectional sample calibration, the production of longitudinal weights for the two panels combined, and a change in the dissemination strategy that raises questions about the usefulness of certain sets of longitudinal and cross-sectional weights.

Acknowledgements

The authors wish to thank Christian Nadeau for all the support and valuable advice he provided throughout the preparation of this document. They are also grateful to Michel Latouche, Guy Laflamme and Martin St-Pierre for their constructive comments.

References

Cotton, C., Bishop, K., Giles, P., Hewer, P. and Saint-Pierre, Y. (1999). *A Comparison of the Results of the Survey of Labour and Income Dynamics (SLID) and the Survey of Consumer Finances (SCF) 1993-1997 : Update* , Statistics Canada publication N °75F0002MIE - 99007.

Dufour, J., Gagnon, F., Morin, Y., Renaud, M. and Särndal, C.E. (1998). *Measuring the Impact of Alternative Weighting Schemes for Longitudinal Data* , Proceedings of the Survey Research Methods Section, American Statistical Association.

Durning, A. (1994). *Weighting of the SLID Preliminary File*, internal document, Statistics Canada.

Franklin, S. (1999a). *Modelling SLID's Nonresponse at the Provincial Level*, internal document, Statistics Canada.

Franklin, S. (1999b). *Study of the Impact of Modifying SLID's Nonresponse Model*, internal document, Statistics Canada.

Franklin, S. and Lévesque, I. (1999). *L'ajout de bruit aux poids post-stratifiés*, internal document, Statistics Canada.

Gagnon, F. (1997). *Pondération longitudinale - Deuxième vague de l'EDTR* , internal document, Statistics Canada.

Gambino, J.G., Singh, M.P., Dufour, J., Kennedy, B. and Lindeyer, J. (1998). *Methodology ot the Canadian Labour Force Survey*, Statistics Canada, Catalogue 71-526-XPB.

Grondin, C. (1996). *Pondération longitudinale - Première vague de l'EDTR* , internal document, Statistics Canada.

Kalton, G. and Kasprzyk, D. (1986). *The Treatment of Missing Survey Data,* Survey Methodology, vol. 12, no 1, pp. 1-16.

Knowledge SEEKER IV, Version 4.2.2, Copyright 1996, Angoss International Limited.

Latouche, M., Dufour, J. and Merkouris, T. (2000). *SLID Cross-Sectional Weighting: Combining Two or More Panels*, internal document, Statistics Canada.

Latouche, M. and Michaud, S. (1997). *Concerns pertaining to weighting of longitudinal surveys*, Proceedings of the Section on Government Statistics and Section on Social Statistics, American Statistical Association.

Lavallée, P. (1994). *Ajout du second panel à l'EDTR: sélection et pondération*, internal document, Statistics Canada.

Lavallée, P. (1995). *Cross-Sectional Weighting of Longitudinal Surveys of Individuals and Households Using the Weight Share Method*, Survey Methodology, vol. 21, no 1, pp. 25-32.

Lavigne, M. and Michaud, S. (1998). *General Aspects of the Survey of Labour Income Dynamics*, Income and Labour Dynamics Working Paper, Statistics Canada, 75F0002M No. 98-05.

Lemaître, G. and Dufour, J. (1987). *An Integrated Method for Weightint Persons and Families*, Survey Methodology, vol. 13, no 2, pp. 119-207.

Merkouris, T. (1999). *Cross-sectional Estimation in Multiple-Panel Household Surveys*, Methodology Branch Working Paper, Statistics Canada, HSMD-99-004E.

Nadeau, C., Gagnon, É. and Latouche, M. (1999). *Disclosure Control Strategy for the Release of Microdata in the Canadian Survey of Labour and Income Dynamics*, Proceedings of the Survey Research Methods Section, American Statistical Association.

Renaud, M. (1997). *Pondération transversale - Deuxième vague de l'EDTR* , internal document, Statistics Canada.

Singh, M.P., Drew, J.D., Gambino, J.G. and Mayda, F. (1990). *Methodology ot the Canadian Labour Force Survey*, Statistics Canada, Catalogue 71-526.

Statistique Canada (1997). *Income Distributions by size in Canada*, Statistics Canada publication N°13-207-XPB, pp. 52-59.

Tambay, J. L., Schiopu-Kratina, I., Mayda, J., Stukel, D. and Nadon, S. (1998). *Treatment of Nonresponse in Cycle Two of the National Population Health Survey*, Survey Methodology, vol. 24, no 2, pp. 147-156.

Tremblay, J. (1998). *Détection des observations influentes pour l'enquête sur les finances des consommateurs (EFC) et l'enquête sur la dynamique du travail et du revenu (EDTR)*, internal document, Statistics Canada.

Appendix A: List of Variables Used in the Nonresponse Adjustment Model

The following variables were used to model nonresponse for the first panel, wave 5:

Aborig	- Aboriginal person
Canada	- born in Canada
US	- born in US
UK	- born in UK
Europe	- born in Europe
Autpays	- born elsewhere (not in Canada, US, UK or Europe)
EOBR	- ethnic origin British
EOCAN	- ethnic origin Canadian
EOEUR	- ethnic origin European
EOFR	- ethnic origin French
IMSTAT	- immigration status
VISMIN	- visible minority
OWNER	- owns home
RURAL	- lives in a rural district (based on EA)
REMOTE	- lives in remote district (based on EA)
URBAIN	- lives in urban district (based on EA)
EMPLOYE	- employed
NEMPLOYE	- unemployed
NLF	- not in labour force
MAR_UL	- married or common law
SEP_DIV	- separated or divorced
VEUF	- widowed
CELIB	- bachelor (never married)
PROX	- preliminary interview was via a proxy respondent
REV0	- indicates if household income was missing in the preliminary interview. This variable was added in 1997 since it was realized that the nonresponse rate for this variable is high: 29%. In previous years, missing was in the same category as <$10,000 (REV1).
REV1	- household income <=$10,000
REV2	- household income > $10,000 and <=$25,000
REV3	- household income > $25,000 and <=$50,000
REV4	- household income > $50,000
PRESENF	- children present at the time of the preliminary interview
P10 – P59	- one variable for each province
HOMME	- sex variable
AGE_1	- age >=16 and <19
AGE_2	- age >=19 and <25
AGE_3	- age >=25 and <35
AGE_4	- age >=35 and <45
AGE_5	- age >=45 and <55
AGE_6	- age >=55 and <65
AGE_7	- age >=65
Educ1 – Educ9	- 9 levels of education

The following variables were used to model nonresponse for the second Panel:

Educ1	- 0-8 years of schooling
Educ2	- 9-13 years of schooling (i.e. secondary)
Educ3	- some post-secondary or a post secondary certificate, diploma
Educ4	- post secondary college or university (incl. PhD)
RENTER	- 1=owns home, 0=rents home
EMPLOYE	- employed
NON_EMPL	- unemployed
NLF	- not in labour force
MARIE	- married or common law
SEP_DIV	- separated or divorced
VEUF	- widowed
CELIB	- bachelor (never married)
P10 – P59	- one variable for each province
SEXE	- sex variable
AGE_1	- age >=16 and <19
AGE_2	- age >=19 and <25
AGE_3	- age >=25 and <35
AGE_4	- age >=35 and <45
AGE_5	- age >=45 and <55
AGE_6	- age >=55 and <65
AGE_7	- age >=65
HHSZ1-HHSZ5	- number of people in the household (HHSZ5=>5)
FAMTYPE1	- unattached individual
FAMTYPE2	- husband-wife or single parent families without young children
FAMTYPE3	- husband-wife or single parent families with children aged 0-17
FAMTYPE4	- other types of families
STUDENTS	- 1=student (full-time or part time), 0=not a student
CWORK1	- class of worker is a public employee
CWORK2	- class of worker is a private employee
CWORK3	- not a public or private employee, specifically: private, self-employed with or without employees or private, working in a family business without pay.

Division de la statistique du revenu

75F0002MIF - 00004

Pondérations longitudinale et transversale de l'Enquête sur la Dynamique du travail et du revenu
Année de référence 1997

Préparé par :
Isabelle Lévesque
Sarah Franklin

Août 2000

Statistique Canada Statistics Canada

Canada

Des données sous plusieurs formes

Statistique Canada diffuse les données sous formes diverses. Outre les publications, des totalisations habituelles et spéciales sont offertes. Les données sont disponibles sur Internet, disque compact, disquette, imprimé d'ordinateur, microfiche et microfilm, et bande magnétique. Des cartes et d'autres documents de référence géographiques sont disponibles pour certaines sortes de données. L'accès direct à des données agrégées est possible par le truchement de CANSIM, la base de données ordinolingue et le système d'extraction de Statistique Canada.

Comment obtenir d'autres renseignements

Toute demande de renseignements au sujet du présent produit ou au sujet de statistiques ou de services connexes doit être adressée à : Services aux clients, Division de la statistique du revenu, Statistique Canada, Ottawa, Ontario, K1A 0T6 ((613) 951-7355; (888) 297-7355; revenu@statcan.ca) ou à l'un des centres de consultation régionaux de Statistique Canada :

Halifax	(902) 426-5331	Regina	(306) 780-5405
Montréal	(514) 283-5725	Edmonton	(403) 495-3027
Ottawa	(613) 951-8116	Calgary	(403) 292-6717
Toronto	(416) 973-6586	Vancouver	(604) 666-3691
Winnipeg	(204) 983-4020		

Vous pouvez également visiter notre site sur le Web : http://www.statcan.ca

Un service d'appel interurbain sans frais est offert **à tous les utilisateurs qui habitent à l'extérieur des zones de communication locale** des centres de consultation régionaux.

Service national de renseignements	**1 800 263-1136**
Service national d'appareils de télécommunications pour les malentendants	**1 800 363-7629**
Numéro pour commander seulement (Canada et États-Unis)	**1 800 267-6677**

Renseignements sur les commandes et les abonnements

Les prix ne comprennent pas les taxes de vente

On peut se procurer ce produit nº 75F0002MIF-00004 au catalogue sur internet. Un numéro coûte 0 $CAN. Pour obtenir un numéro de ce produit, les utilisateurs sont priés de se rendre à http://www.statcan.ca/cgi-bin/downpub/freepub_f.cgi.

Normes de service à la clientèle

Statistique Canada s'engage à fournir à ses clients des services rapides, fiables et courtois et dans la langue officielle de leur choix. À cet égard, notre organisme s'est doté de normes de service à la clientèle qui doivent être observées par les employés lorsqu'ils offrent des services à la clientèle. Pour obtenir une copie de ces normes de service, veuillez communiquer avec le centre de consultation régional de Statistique Canada le plus près de chez vous.

Statistique Canada
Division de la statistique du revenu

Pondérations longitudinale et transversale de l'Enquête sur la Dynamique du travail et du revenu
Année de référence 1997

Publication autorisée par le ministre responsable de Statistique Canada

© Ministre de l'Industrie, 2000

Tous droits réservés. Il est interdit de reproduire ou de transmettre le contenu de la présente publication, sous quelque forme ou par quelque moyen que ce soit, enregistrement sur support magnétique, reproduction électronique, mécanique, photographique, ou autre, ou de l'emmagasiner dans un système de recouvrement, sans l'autorisation écrite préalable des Services de concession des droits de licence, Division du marketing, Statistique Canada, Ottawa, Ontario, Canada K1A 0T6

août 2000

N° 75F0002MPF - 00004 au catalogue
ISSN 0000-0000

N° 75F0002MIF - 00004 au catalogue
ISSN 0000-0000

Périodicité : Irr.

Ottawa

This publication is available in English upon request.

Note de reconnaissance

Le succès du système statistique du Canada repose sur un partenariat bien établi entre Statistique Canada et la population, les entreprises, les administrations canadiennes et les autres organismes. Sans cette collaboration et cette bonne volonté, il serait impossible de produire des statistiques précises et actuelles.

PUBLICATIONS ÉLECTRONIQUES DISPONIBLES À

www.statcan.ca

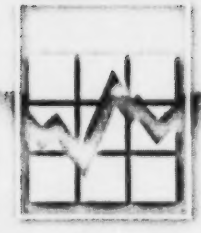

RÉSUMÉ

L'Enquête sur la Dynamique du travail et du revenu (EDTR), introduite à l'année de référence 1993, est une enquête longitudinale par panel menée auprès des individus. Elle vise à mesurer les changements au niveau du bien-être économique des individus et les facteurs qui peuvent influencer ces changements. L'échantillon de l'EDTR est divisé en deux panels qui se chevauchent, d'une durée de six ans chacun. Les enquêtes longitudinales, comme l'EDTR, sont particulières de par la nature dynamique de la composition de leur échantillon, engendrée directement par la dynamique des familles et des ménages au fil des ans. À chaque année de référence, l'EDTR produit deux ensembles de poids : un ensemble de poids qui est représentatif de la population initiale (l'aspect longitudinal) et un autre qui est représentatif de la population actuelle (l'aspect transversal). Pour la production de poids transversaux, l'EDTR combine deux échantillons indépendants et assigne une probabilité de sélection aux individus qui se sont joints à l'échantillon après la sélection de l'échantillon initial. Les poids longitudinaux tout comme les poids transversaux sont ajustés pour la non-réponse, les valeurs influentes et la confidentialité, et un redressement de l'échantillon est effectué pour représenter la population cible. Le but de ce document est donc de décrire la méthodologie employée à l'EDTR pour pondérer les échantillons longitudinal et transversal, et de présenter les développements importants à venir. Afin de mieux illustrer la stratégie de pondération, les résultats de l'année de référence 1997 sont utilisés.

TABLE DES MATIÈRES

1. Introduction 9

2. Méthodologie d'enquête 11

3. Pondération longitudinale 17
   - 3.1 Détermination des poids initiaux 17
   - 3.2 Classification des individus longitudinaux 18
   - 3.3 Modélisation et ajustement pour la non-réponse 20
   - 3.4 Ajustement pour les valeurs influentes 24
   - 3.5 Stratification a posteriori 25
   - 3.6 Ajout de bruit 26
   - 3.7 Description des poids longitudinaux finaux produits 27

4. Pondération transversale 29
   - 4.1 Détermination des individus éligibles à la pondération transversale . 30
   - 4.2 Ajustement pour la non-réponse 30
   - 4.3 Application des facteurs d'allocation des panels 31
   - 4.4 Partage des poids 34
   - 4.5 Ajustement pour la migration inter-provinciale 37
   - 4.6 Ajustement pour les valeurs influentes 38
   - 4.7 Stratification a posteriori 40
   - 4.8 Ajout de bruit 41
   - 4.9 Description des poids transversaux finaux produits 41

5. Changements à venir et développements futurs 43

6. Conclusion 45

Remerciements 47

Bibliographie 49

Annexe A : Liste des variables utilisées dans le modèle d'ajustement pour la non-réponse 51

1. Introduction

L'Enquête sur la Dynamique du travail et du revenu (EDTR), introduite à l'année de référence 1993, est une enquête longitudinale par panel menée auprès des individus. Elle vise à mesurer les changements au niveau du bien-être économique des individus et les facteurs qui peuvent influencer ces changements, plus particulièrement les facteurs déterminants au niveau des caractéristiques démographiques, familiales et au niveau de l'activité. Le produit final de l'enquête est un ensemble de fichiers de microdonnées. Pour un aperçu général de l'enquête, se référer à Lavigne et Michaud (1998).

Originalement, l'objectif principal de l'EDTR visait à fournir des données longitudinales afin de produire des estimations et des analyses du point de vue longitudinal. L'aspect transversal de l'enquête est maintenant devenu tout aussi important que l'aspect longitudinal, entre autre en raison de l'intégration de l'Enquête sur les finances des consommateurs (EFC), une enquête transversale, à l'EDTR (Cotton et coll., 1999). La combinaison de ces deux enquêtes s'est faite à partir de l'année de référence 1998. Pour plus de renseignements sur l'EFC, se référer à Statistique Canada, 1997.

La pondération d'une enquête longitudinale peut parfois s'avérer un grand défi méthodologique, tant par ses aspects longitudinal et transversal, que par la nature dynamique de la composition du panel (engendrée directement par la dynamique des familles et des ménages au fil des ans). De nombreux défis se sont ajoutés au cours des années du point de vue de la pondération et plusieurs autres sont à venir : la combinaison de panels qui se chevauchent, l'intégration de l'EFC, le changement de logiciel utilisé pour la modélisation de la non-réponse, l'augmentation du nombre de post-strates pour les groupes d'age et sexe et l'ajout de nouvelles post-strates (nombre d'entités économiques, groupes de revenu), les changements au niveau du traitement des données, etc. Toutes ces considérations ajoutent à la complexité des pondérations longitudinale et transversale de l'EDTR.

Le but premier du présent document est de présenter les différentes étapes de la pondération, tant longitudinale que transversale, telles qu'utilisées lors de la production des poids pour l'année de référence 1997. Le deuxième objectif est de soulever certaines préoccupations et questions relatives à quelques-unes des étapes de la pondération. Et le troisième objectif consiste à informer le lecteur des développements futurs et des changements importants à venir en ce qui concerne la pondération. Le document est divisé en cinq sections. Tout d'abord, la méthodologie de l'enquête est donnée à la section 2. Ensuite, les étapes de la pondération longitudinale, de la détermination des poids initiaux à l'obtention des poids longitudinaux finaux, sont décrites à la section 3. Puis, toutes les étapes de la pondération transversale sont discutées à la section 4. De plus, les considérations futures sont présentées à la section 5. Et finalement, la conclusion est donnée à la section 6.

Ce document s'inspire en partie des documents qui ont été écrits jusqu'à maintenant sur la pondération de l'EDTR (Grondin, 1996; Gagnon, 1997; Renaud, 1997). Ces documents portent sur les années de référence 1993 et 1994. Comme plusieurs changements et nouveautés ont été apportés à la méthodologie des pondérations longitudinale et transversale depuis, la rédaction d'un nouveau document s'est alors avérée nécessaire.

2. Méthodologie d'enquête

L'échantillon de l'EDTR est constitué de deux panels d'une durée de six ans chacun (ou six vagues). Le premier panel, sélectionné en janvier 1993, couvre la population des personnes habitant dans les dix provinces canadiennes au 31 décembre 1992. Le deuxième panel a été sélectionné en janvier 1996 et représente la population des personnes dans les dix provinces canadiennes au 31 décembre 1995. La population couverte pour chacun des deux panels exclut les personnes résidant dans une réserve indienne, les membres à temps plein des Forces armées canadiennes habitant dans les casernements militaires ainsi que les pensionnaires dans les établissements institutionnels pour plus de six mois. Dans ce document, tout ce qui fera référence à la population des dix provinces canadiennes implique toutes ces exclusions.

Un nouveau panel est introduit à tous les trois ans pour remplacer le panel le plus âgé. Ceci étant fait dans le but d'améliorer la représentativité de l'échantillon transversal (pour tenir compte des nouveaux ménages qui se sont ajoutés à la population depuis trois ans), de diminuer l'effet de l'érosion et de réduire le fardeau de réponse. La figure 2.1 donne un aperçu de la sélection des panels et du chevauchement entre ceux-ci.

Figure 2.1 : Chevauchement des panels de l'EDTR

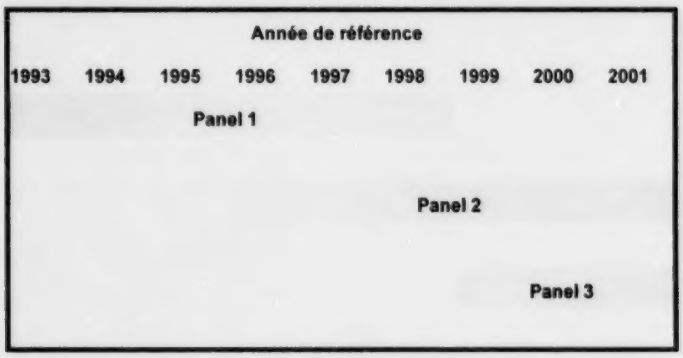

Chaque panel de l'EDTR consiste en un sous-échantillon d'environ 15 000 ménages (approximativement 40 000 personnes) provenant de l'Enquête sur la population active (EPA). L'échantillon de l'EPA est prélevé d'une base aréolaire selon un plan de sondage probabiliste à plusieurs degrés. L'EPA fonctionne sur une base de six panels (groupes de renouvellement) d'une durée de six mois chacun dont un est renouvelé à tous les mois. L'unité d'échantillonnage au dernier degré est le logement. Ainsi tous les individus appartenant aux ménages qui occupent les logements choisis font partie de l'échantillon de l'EPA. Pour plus de renseignements sur l'EPA, se référer aux documents décrivant la méthodologie de cette enquête (Singh et coll., 1990; et Gambino et coll., 1998).

Les ménages sélectionnés pour l'EDTR sont ceux faisant partie des groupes de renouvellement sortant des panels de l'EPA aux deux premiers mois de la première période de référence de l'EDTR (soit en janvier et février 1993 pour le premier panel, et en janvier et février 1996 pour le deuxième panel). Le fichier de l'EPA de janvier est celui dont l'EDTR se sert pour choisir son échantillon de départ. Parmi tous les ménages faisant partie des groupes de renouvellement sortant de l'EPA en janvier ou février, l'EDTR sélectionne seulement les ménages qui sont répondants à l'EPA en janvier. La dernière interview de

l'EPA sert alors de premier contact pour introduire l'EDTR. Une interview préliminaire est d'abord administrée à chaque personne sélectionnée par l'EDTR. Cette interview recueille des renseignements de base sur l'expérience de travail, les antécédents familiaux et personnels, et le niveau d'instruction.

Pour le premier panel, l'EDTR a mené l'interview préliminaire en même temps que la dernière interview de l'EPA. À cause de contraintes budgétaires, les ménages répondants à l'interview préliminaire ont dû être sous-échantillonnés; l'échantillon longitudinal pour le premier panel ne comprend que les personnes de ces ménages. Un sous-échantillon des non-répondants à cette interview a aussi été choisi pour permettre d'étudier le biais causé par la non-réponse. Même si des données sont recueillies pour ces ménages, elles ne sont pas utilisées pour la production. Cet échantillon ne sera donc pas considéré ici.

Pour le deuxième panel, l'interview préliminaire a été menée en même temps que les interviews de la première vague pour diminuer les frais associés à la collecte des données de l'EDTR. L'échantillon longitudinal pour le deuxième panel comprend alors toutes les personnes auxquelles on a administré une interview préliminaire (répondantes et non-répondantes). Les figures 2.2 et 2.3 donnent un apreçu de la sélection des ménages pour l'EDTR. Plus de détails sur la sélection des panels de l'EDTR sont donnés à la section 3.1.

Figure 2.2 : Sélection des ménages pour l'échantillon longitudinal de l'EDTR - panel 1

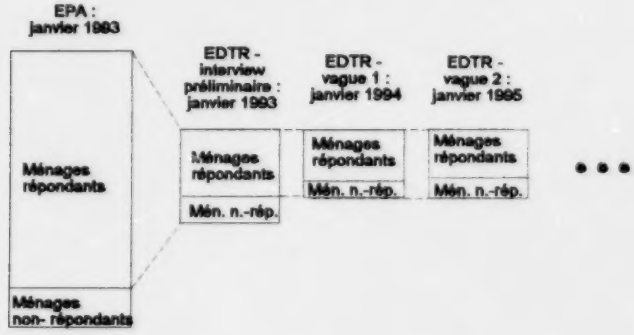

Figure 2.3 : Sélection des ménages pour l'échantillon longitudinal de l'EDTR - panel 2

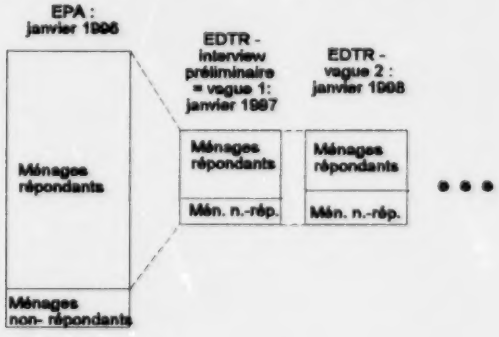

Chaque personne sélectionnée pour l'EDTR est ensuite interviewée deux fois par année pendant six ans. À chaque année, des informations sont recueillies concernant la composition de la famille et du ménage, l'activité et les revenus de l'année précédente. En janvier, l'information sur l'activité est recueillie alors qu'en mai, on obtient de l'information sur le revenu. Afin de réduire le fardeau de réponse, les répondants peuvent éviter la collecte de mai en préautorisant Statistique Canada à utiliser leur dossier fiscal de Revenu Canada.

À la sélection d'un panel, toutes les personnes faisant partie des ménages choisis pour l'EDTR, indépendamment de l'âge de ces personnes, deviennent des membres de l'échantillon longitudinal du panel. Ces personnes sont considérées comme des membres de l'échantillon longitudinal pendant les six ans de participation du panel, même si elles déménagent, meurent, entrent en institution ou deviennent membres des forces armées à temps plein à l'intérieur des campements militaires. Aucune autre personne ne devient membre de l'échantillon longitudinal pour ce panel. Ainsi, pour chaque panel, l'échantillon longitudinal est constitué au moment de l'introduction du panel et reste tel quel pendant toute la durée du panel. La population ciblée par l'échantillon longitudinal demeurera la même tout au long des six années de participation du panel à l'enquête.

Du point de vue longitudinal, l'unité d'intérêt est l'individu; le ménage pouvant difficilement servir d'outil d'analyse longitudinale à cause de sa nature dynamique dans le temps. Du point de vue transversal, on s'intéresse aussi bien à l'individu qu'au ménage. Comme l'EDTR s'intéresse non seulement aux caractéristiques des personnes longitudinales mais aussi aux caractéristiques du ménage, on interviewe toutes les personnes habitant avec au moins un individu longitudinal. L'échantillon transversal pour une année donnée est alors constitué de toutes les personnes longitudinales dans le champ de l'enquête au 31 décembre de l'année de référence correspondante, et de toutes les personnes qui habitent avec elles à ce moment précis de l'année. Une personne est considérée dans le champ de l'enquête au 31 décembre d'une année de référence donnée (dans le champ de l'enquête transversalement) si elle habite dans une des dix provinces canadiennes, ne réside pas dans une réserve indienne ou un établissement institutionnel depuis plus de six mois, et n'est pas un membre à temps plein des Forces armées canadiennes habitant dans un casernement militaire, à ce moment de l'année. Toute personne longitudinale qui est dans le champ de l'enquête transversalement fera aussi parti de l'échantillon transversal. Toutes les personnes interviewées qui ne font pas partie de l'échantillon longitudinal sont appelées cohabitants. Il est à noter que l'ajout des cohabitants à l'échantillon transversal aide à améliorer la représentativité de l'échantillon transversal (Latouche, Michaud, 1997).

À chaque année, des poids longitudinaux et transversaux sont produits pour satisfaire ces besoins. La pondération longitudinale vise donc à produire des estimations qui sont représentatives de la population des dix provinces canadiennes au moment de la sélection de l'échantillon longitudinal alors que la pondération transversale permet de produire des estimations représentatives de la population des dix provinces canadiennes en date du 31 décembre d'une année de référence donnée. Par exemple, les estimations produites à partir de l'échantillon longitudinal du premier panel sont représentatives de la population des dix provinces canadiennes au 31 décembre 1992 et celles produites avec l'échantillon longitudinal du deuxième panel font référence à la population des dix provinces canadiennes au 31 décembre 1995. Les estimations produites à partir de l'échantillon transversal pour l'année de référence 1997 représentent la population des dix provinces canadiennes au 31 décembre 1997.

En janvier 1993, 39 745 personnes ont été sélectionnées pour faire partie de l'échantillon longitudinal du premier panel. En janvier 1996, 43 547 personnes ont été choisies pour faire partie de l'échantillon longitudinal du deuxième panel. L'échantillon transversal pour

l'année de référence 1997 comprend 81 090 individus, dont 70 372 personnes longitudinales.

Le tableau 2.1 donne un aperçu des changements dans la constitution des échantillons longitudinaux au cours du temps. Le tableau 2.2 présente la constitution des échantillons transversaux pour chacune des années de référence traitées jusqu'à maintenant (1993 à 1997 inclusivement).

Tableau 2.1 : Constitution des échantillons longitudinaux des deux panels (nombre de personnes)

Année de référence		1993	1994	1995	1996	1997
Panel 1	**Personnes contactées à l'interview**					
	Dans le champ de l'enquête au 31 décembre d'une année de référence donnée[1]	39 456	36 241	34 336	33 159	31 802
	Habitant en dehors des dix provinces canadiennes	28	37	45	150	280
	En institution	81	119	278	256	280
	Décédée	180	408	657	908	1 134
	Duplicata, erreur	0	0	1	1	1
	Personnes non contactées à l'interview[3]					
	Refus ferme, personnes dans les ménages non dépistés[2]	0	2940	4428	5271	6 248
	Total	39 745	39 745	39 745	39 745	39 745
Panel 2	**Personnes contactées à l'interview**					
	Dans le champ de l'enquête au 31 décembre d'une année de référence donnée[1]	-----	-----	-----	41 767	38 366
	Habitant en dehors des dix provinces canadiennes	-----	-----	-----	126	270
	En institution	-----	-----	-----	40	120
	Décédée	-----	-----	-----	234	466
	Duplicata, erreur	-----	-----	-----	0	2
	Personnes non contactées à l'interview[3]					
	Refus ferme, personnes dans les ménages non dépistés	-----	-----	-----	1 380	4 323
	Total	-----	-----	-----	43 547	43 547

1 Habitant toujours dans les dix provinces canadiennes, n'est pas décédé, ne réside pas dans un établissement institutionnel depuis plus de six mois.

2 On ne considère pas dans cette catégorie les cas de refus à l'interview préliminaire de l'EDTR et à l'interview de l'EPA.

3 Avant l'année de référence 1997, cette catégorie comprend les cas de refus ferme ou les cas non dépistés à la collecte d'une année de référence donnée. À partir de l'année de référence 1997, les cas inclus dans cette catégorie font tous référence à la collecte précédente.

Tableau 2.2 : Constitution des échantillons transversaux, par panel (nombre de personnes)

Année de référence	1993	1994	1995	1996	1997
Panel 1					
Personnes longitudinales	39 456	36 241	34 336	33 159	31 802
Cohabitants	2 062	3 640	4 620	5 768	6 655
	41 518	39 881	38 956	38 927	38 457
Panel 2					
Personnes longitudinales	----	----	----	41 767	38 366
Cohabitants	----	----	----	2 351	4 011
	----	----	----	44 118	42 377
Total	41 518	39 881	38 956	83 045	80 834

L'EDTR a pour mandat de fournir des données longitudinales et transversales sur les caractéristiques reliées à l'activité et au revenu, et de rendre ces données disponibles aux utilisateurs aussi bien à l'intérieur qu'à l'extérieur de Statistique Canada. Pour ce faire, un ensemble de fichiers de microdonnées non traitées pour la confidentialité (fichiers internes) et un ensemble de fichiers de microdonnées traitées pour la confidentialité (fichiers externes) sont produits par l'EDTR. Les fichiers internes sont disponibles seulement pour les utilisateurs de Statistique Canada, ils comprennent alors des poids qui n'ont pas reçu de traitement pour la confidentialité (*poids internes*). Quant aux fichiers externes, produits pour les utilisateurs de l'extérieur de Statistique Canada, ils sont traités pour la confidentialité. Pour cette raison, du bruit est ajouté dans tous les poids fournis sur ces fichiers (*poids externes*).

Après le traitement des données d'une année de référence donnée, les utilisateurs de Statistique Canada peuvent avoir accès à la base de données relationnelle pour faire leurs analyses transversales et longitudinales. Toute information sur cette base de données est confidentielle étant donné qu'elle n'a pas reçu de traitement pour la confidentialité. Les poids internes et externes, de même que certaines autres données traitées pour la confidentialité, sont aussi disponibles sur cette base de données.

Des fichiers transversaux et longitudinaux internes sont aussi produits pour les utilisateurs de Statistique Canada pour faciliter l'accès aux données. Plus de travail est nécessaire pour diffuser les fichiers externes puisque ces derniers doivent être traités pour la confidentialité. L'ensemble des méthodes de contrôle de la divulgation est évaluée et améliorée pour assurer la confidentialité des données fournies. Pour l'année de référence 1997, la stratégie de diffusion initialement prévue consistait à produire un ensemble de fichiers transversaux et longitudinaux de microdonnées à grande diffusion.

Les fichiers transversaux (faisant référence à l'année de référence traitée) comprennent toutes les personnes (longitudinaux et cohabitants) de 16 ans et plus dans les ménages répondants qui sont dans le champ de l'enquête au 31 décembre de l'année de référence ciblée. Les fichiers longitudinaux (comprenant les informations de la première année de référence jusqu'à l'année de référence la plus à jour) incluent toutes les personnes longitudinales, peu importe leur statut. Le contenu des fichiers transversaux et

longitudinaux est très similaire. Une des particularités de cette stratégie de diffusion est qu'elle ne permettait pas la reconstitution des ménages au sein des fichiers de microdonnées diffusés (pour des raisons de confidentialité). Cependant à cause de contraintes de temps, la diffusion de microdonnées pour l'année de référence 1997 n'a pas encore été faite.

3. Pondération longitudinale

Cette section a pour but de décrire la méthodologie utilisée pour pondérer à chaque vague les individus longitudinaux de l'EDTR. Afin de mieux illustrer la méthodologie utilisée, des exemples tirés de la cinquième vague du premier panel et de la deuxième vague du deuxième panel sont présentés. Il est important de rappeler que les poids longitudinaux visent à représenter la population des dix provinces canadiennes au 31 décembre 1992 pour le premier panel et au 31 décembre 1995 pour le deuxième panel.

L'EDTR produit deux ensembles de poids longitudinaux : un ensemble de poids internes et un ensemble de poids externes. Les poids externes sont utilisés par les utilisateurs à l'extérieur de Statistique Canada, du bruit étant ajouté à ces poids afin de rendre plus difficile la construction des familles et des ménages. Il est important de noter que les ensembles de poids longitudinaux sont produits pour les deux panels séparément.

La pondération longitudinale s'effectue selon les six étapes présentées aux sections suivantes : la détermination des poids initiaux (section 3.1), la classification des individus longitudinaux (section 3.2), la modélisation et l'ajustement pour la non-réponse (section 3.3), l'ajustement pour les valeurs influentes (section 3.4), la stratification a posteriori (section 3.5) et l'ajout de bruit (section 3.6). Une description des poids longitudinaux finaux produits est donnée à la section 3.7.

3.1 Détermination des poids initiaux

Pour le premier échantillon de l'EDTR (premier panel), les ménages répondants des deux groupes de rotation sortant de l'EPA au mois de janvier ou février 1993 ont d'abord été choisis pour un total de 20 486 ménages. Parmi ces ménages, 17 659 ménages ont répondu à l'interview préliminaire de l'EDTR, alors que les 2 827 autres ménages ont été non-répondants. Pour des raisons budgétaires, il a été décidé de réduire la taille de l'échantillon initial de l'EDTR à environ 15 000 ménages. Pour ce faire, les ménages répondants à l'interview préliminaire ont été sous-échantillonnés avec un processus de Poisson ayant comme paramètre 0,84. De la même façon, les ménages non-répondants à l'interview préliminaire ont été sous-échantillonnés également avec un processus de Poisson mais cette fois avec un paramètre de 0,06. Ainsi, l'échantillon réduit était formé de 14 832 ménages répondants (39 745 personnes) et de 174 ménages non-répondants (410 personnes).

Pour des raisons budgétaires, seuls les ménages ayant répondu à l'interview préliminaire (14 832) ont été retenus pour faire partie de l'échantillon initial du premier panel de l'EDTR. Une étude a démontré que les impacts d'une telle décision seraient relativement faibles (Durning, 1994). Quoiqu'ils ont été exclus de l'échantillon final, les 174 ménages non-répondants à l'interview préliminaire ont été conservés pour des fins d'analyse. L'ensemble de ces ménages est appelé échantillon de qualité. Cet échantillon ne sera pas pris en considération dans ce document.

La sélection de l'échantillon du second panel de l'EDTR s'est effectuée de manière beaucoup plus simple : tous les ménages qui ont répondu à l'EPA en janvier 1996 et qui faisaient partie des groupes de renouvellement sortant des panels de l'EPA en janvier et février 1996, ont été sélectionnés (16 472 ménages pour un total de 43 547 personnes). Les interviews préliminaires du deuxième panel ont été menées en même temps que les interviews de la première vague (c'est-à-dire en janvier 1997).

Les poids initiaux de la pondération longitudinale correspondent à l'inverse de la probabilité de sélection du ménage. Ainsi tous les membres longitudinaux d'un même ménage (celui auquel ils appartenaient lors de la sélection de l'échantillon) ont le même poids initial.

L'échantillon de l'EDTR étant tiré de l'échantillon de l'EPA, le poids initial sera donc :

$$w_{initial,p_1} = w_{EPA} * 3 * 1{,}19$$
$$w_{initial,p_2} = w_{EPA} * 3$$

où $w_{initial,p_1}$ = poids longitudinal initial pour le panel 1
$w_{initial,p_2}$ = poids longitudinal initial pour le panel 2
w_{EPA} = poids de l'EPA ajusté pour la non-réponse (sous-poids de l'EPA)
3 = inverse de la probabilité de sélection des groupes de rotation de l'EPA (2 groupes sur 6 ont été sélectionnés)
1.19 = inverse de la fraction de sondage du sous-échantillon de répondants à l'interview préliminaire du panel 1 (sélectionné selon un processus de Poisson).

3.2 Classification des individus longitudinaux

À chaque vague, la première étape de la pondération longitudinale est de classer les individus longitudinaux parmi les catégories suivantes : les non-répondants (dans les ménages répondants ou non-répondants), les répondants qui sont dans le champ de l'enquête transversalement et les personnes qui sont hors du champ de l'enquête transversalement. Un ménage répondant est un ménage dans lequel il y a au moins une personne qui ait répondu à au moins une des deux interviews (l'interview sur le travail ou l'interview sur le revenu). Un ménage non-répondant est un ménage dans lequel tous les membres du ménage sont non-répondants aux deux interviews. Une personne est considérée hors du champ de l'enquête transversalement (ou non-éligible transversalement) si, au 31 décembre de l'année de référence, elle était décédée, en institution pour plus de six mois ou ne résidait pas dans une des dix provinces canadiennes.

La classification des individus longitudinaux permet de déterminer les personnes qui devraient recevoir un poids longitudinal non nul. Un poids longitudinal de zéro est attribué aux individus dans les ménages non-répondants. Tous les autres individus qui étaient sélectionnés initialement pour faire partie de l'échantillon longitudinal ont un poids longitudinal non nul, même s'ils sont hors du champ de l'enquête transversalement (puisqu'ils sont considérés comme étant répondants). Il est à noter que du point de vue de la pondération, l'EDTR définit les personnes non-répondantes dans les ménages répondants comme répondantes. Cela est fait pour assurer la cohérence intra-ménage au niveau des poids (les données des personnes non-répondantes dans les ménages répondants sont alors imputées).

La classification des individus longitudinaux permet aussi de déterminer si le poids d'un individu devrait être ajusté pour la non-réponse, en plus d'identifier les individus qui seront utilisés dans le modèle d'ajustement pour la non-réponse. Ce modèle sert à trouver un ajustement adéquat pour gonfler les poids des répondants afin que ces derniers soient représentatifs de l'ensemble des répondants et des non-répondants.

Un ajustement pour la non-réponse est habituellement appliqué aux poids de toutes les unités répondantes de l'enquête. Dans le cas de l'EDTR, un facteur d'ajustement pour la non-réponse est appliqué aux poids de toutes les personnes considérées comme

répondantes, à l'exception des personnes qui sont hors champ transversalement et des enfants dans les ménages répondants. Dans le cas des personnes qui sont hors du champ de l'enquête transversalement, aucun facteur d'ajustement pour la non-réponse n'est appliqué à leur poids puisqu'on surestime déjà leur nombre (Franklin, 1999b). Dans le cas des enfants, leur poids n'est pas non plus ajusté pour compenser pour la non-réponse. La raison pour cela est que trop peu d'information est recueillie sur eux pour qu'il soit possible de modéliser adéquatement la non-réponse. Un ajustement pour compenser pour la non-réponse est fait implicitement lors de la stratification a posteriori.

Le tableau 3.1 présente les différentes catégories de réponse des individus longitudinaux pour la cinquième vague du premier panel et la deuxième vague du second panel. La colonne *Modélisation de la non-réponse* indique quelles catégories d'individus sont utilisées dans le modèle d'ajustement pour la non-réponse. Les trois dernières colonnes indiquent quel traitement sera appliqué aux poids des individus des différentes catégories.

Tableau 3.1 : Classification des individus longitudinaux pour la cinquième vague du premier panel et la deuxième vague du second panel

Classification des individus		Panel 1 vague 5	Panel 2 vague 2	Modélisation de la non-réponse	$W_{ajust} = 0$	$W_{ajust} = W_{initial}$ (non-gonflés)	$W_{ajust} = W_{initial} / R_{GHR}$ (gonflés)
ENFANTS **0-15 ans (au 31 déc. 1997)**	Dans un ménage non-répondant	1 043	1 057		●		
	Dans un ménage répondant	5 530	7 986			●	
	Dans un ménage non-éligible transversalement (en institution, décédé ou en dehors des provinces)	39	65			●	
ADULTES **16 ans et + (au 31 déc. 1997)**	Non-éligibles transversalement (en institution, décédé ou en dehors des provinces)	1 513	705			●	
	Répondants	25 819	29 002	✔			●
	Non-répondants dans un ménage non-répondant	5 648	4 407	✔	●		
	Duplicata, erreur	1	2		●		
	Non-répondants dans un ménage répondant (seront imputés)	151	323				●
Échantillon de qualité[1]		411	—		●		
Total		40,155	43,547				

[1] Cette catégorie contient toutes les personnes longitudinales faisant partie de l'échantillon de qualité, de même que toute personne longitudinale qui se trouve dans un ménage contenant au moins un membre de l'échantillon de qualité (ce qui est le cas d'une personne pour l'année de référence 1997).

3.3 Modélisation et ajustement pour la non-réponse

Une fois les poids initiaux calculés, il faut maintenant calculer un facteur d'ajustement pour la non-réponse pour chaque individu considéré comme répondant, à l'exception de ceux qui sont hors champ transversalement et des enfants dans les ménages répondants. Rappelons ici que les deux panels sont traités séparément. Le facteur d'ajustement pour la non-réponse appliqué à un individu est défini comme étant l'inverse du taux de réponse du groupe homogène de réponse (GHR) dans lequel l'individu se situe. Les GHR sont formés en regroupant ensemble des individus dont les caractéristiques qui expliquent la non-réponse sont similaires. Si les GHR sont définis de telle sorte que la non-réponse soit complètement aléatoire à l'intérieur d'un groupe, alors le biais dû à la non-réponse est négligeable (Tambay et coll., 1998). Pour trouver un ajustement adéquat pour gonfler les poids des répondants afin que ces derniers soient représentatifs de l'ensemble des répondants et des non-répondants, on procède à la modélisation de la non-réponse.

La première étape de la modélisation de la non-réponse consiste à déterminer quelles sont les variables explicatives qui doivent être considérées dans le modèle afin de bien prédire la variable dichotomique *réponse* (dont les modalités sont simplement *répondant* ou *non-répondant*). La manière la plus simple de choisir ces variables est d'utiliser des informations recueillies à l'EPA, c'est-à-dire avant les premières interviews de l'EDTR. L'avantage d'utiliser ces informations est qu'elles sont disponibles pour tous les individus longitudinaux, qu'ils soient répondants ou non à la vague en traitement. Cependant, certaines des variables recueillies sont de nature dynamique (comme le revenu, le niveau d'éducation, l'état matrimonial, l'emploi, la présence d'enfants, etc.) et risquent d'être désuètes à la date de référence de la vague traitée. Mais si on décidait d'utiliser, pour chaque individu, les informations connues les plus à jour, on risquerait de détenir des informations provenant de périodes de référence différentes (à cause de la non-réponse observée à la vague en traitement). En d'autres termes, l'information la plus à jour serait utilisée pour les répondants, alors que pour les non-répondents, de l'information plus ancienne devrait être utilisée. De plus, en considérant l'information la plus à jour pour la modélisation de la non-réponse, il faudrait utiliser le poids associé à la vague précédant la vague en traitement comme poids de départ au lieu d'utiliser le poids initial de l'EDTR. Mais là vient aussi le problème des non-répondants convertis; ce sont des personnes qui sont répondantes deux vagues précédant la vague en traitement, non-répondantes à la vague précédente mais répondantes à la vague en traitement. Comme les non-répondants convertis ont un poids longitudinal nul à la vague précédant celle en traitement, il faudrait trouver une façon de leur assigner un poids de départ. Une des façons serait de se servir du poids calculé deux vagues précédant celle en traitement. Il faudrait alors s'assurer que la méthode utilisée pour assigner des poids de départ qui proviennent de périodes différentes est acceptable du point de vue méthodologique.

La possibilité d'utiliser l'information la plus à jour pour la modélisation de la non-réponse avait aussi été rejetée parce que l'on croyait que l'effet cumulatif de tous ces modèles de non-réponse donnerait des estimations qui seraient trop dépendantes des modèles de non-réponse.

L'EDTR a donc choisi de ne considérer que l'information connue recueillie avant le début de la collecte des données de l'EDTR. Pour le premier panel, cette information a été prise de l'interview préliminaire étant donnée que l'interview préliminaire avait été menée au moment de la dernière interview de l'EPA. Pour le deuxième panel, l'information considérée est celle qui a été recueillie lors de la dernière interview de l'EPA.

On effectue la première étape de la modélisation de la non-réponse (qui est de déterminer les variables explicatives) seulement lors du traitement de la première vague d'un panel

étant donné qu'on fixe dès le départ les variables à considérer dans le modèle de non-réponse. Aux vagues suivantes, les variables choisies lors de la modélisation de la non-réponse à la première vague sont utilisées. Pour déterminer les variables explicatives à considérer pour la modélisation de la non-réponse, les variables catégoriques dont le nombre de modalités (m) est supérieur à 2 sont recodées en m variables dichotomiques. À partir de toutes ces variables, on établit subjectivement une liste des variables les plus susceptibles d'influencer la réponse.

Pour chacune des variables de cette liste, des régressions logistiques sont produites en prenant une variable à la fois. D'après les résultats de ces régressions logistiques univariées, les variables qui sont significatives sont retenues. En tout, 57 et 43 variables dichotomiques ont été conservées pour le premier et le deuxième panels respectivement. La liste complète de ces variables est fournie par panel à l'annexe A. Comme mentionné précédemment, les mêmes variables sont conservées d'une vague à l'autre d'un même panel; les seuls changements habituellement effectués sont des modifications aux modalités de certaines variables (comme les variables de groupe d'âge et de revenu).

La deuxième étape est de dériver les GHR en considérant les variables retenues à l'étape précédente. Avant l'année de référence 1996, l'EDTR utilisait la régression logistique pour déterminer les GHR en utilisant le type de sélection STEPWISE de la procédure LOGISTIC de SAS. Depuis l'année de référence 1996, l'EDTR utilise la méthode de modélisation par segmentation pour déterminer les GHR, en se servant du logiciel Knowledge Seeker (version 4.2.2). Cette méthode est préférée à la régression logistique puisqu'elle est plus efficace pour réduire le biais dû à la non-réponse (Dufour et coll., 1998).

La modélisation par segmentation utilise un processus itératif pour partitionner le fichier de données et ainsi former l'arbre de décision. Le premier noeud de l'arbre de décision est tout simplement l'ensemble complet des données. La première itération définit le premier embranchement de l'arbre. Ce dernier est créé en déterminant la variable qui influence le plus significativement la variable réponse parmi les variables retenues pour la modélisation. Une mesure statistique reflétant l'importance de la variable pour discriminer la non-réponse est calculée pour chaque variable; et d'après cette mesure, la variable qui est la plus importante significativement est choisie. Le premier embranchement est ainsi formé, créant un noeud à chaque extrémité. Pour chaque noeud formé, une nouvelle itération est effectuée en répétant le même mécanisme. De nouveaux embranchements et de nouveaux noeuds sont alors créés. Si, pour un noeud donné, aucune variable n'est significative pour expliquer la réponse, alors aucun autre embranchement n'est créé. La formation de cette branche de l'arbre est alors complétée. Le processus itératif se termine lorsque toutes les branches de l'arbre sont achevées.

Plusieurs méthodes peuvent être employées pour déterminer la variable qui influence le plus la variable réponse. L'EDTR utilise l'algorithme CHAID ("Chi-Square Automatic Interaction Detection"), qui sélectionne la variable avec la valeur de la statistique du chi-deux de Pearson la plus élevée.

Une des raisons pour laquelle la modélisation par segmentation est préférable à la régression logistique est qu'elle est plus flexible. La régression logistique force le modèle à être symétrique : une fois que les variables significatives sont déterminées, les GHR sont formés en prenant toutes les combinaisons possibles de l'intersection entre ces variables. En forçant le modèle à être symétrique, de petites cellules ou des cellules qui ne sont pas significatives peuvent être formées, ce qui peut affecter la fiabilité des estimations. La modélisation par segmentation permet au modèle d'être asymétrique : à chaque embranchement de l'arbre de décision, on détermine quelle variable est la plus significative;

ce qui garantie que chaque RHG formé est significatif et résulte habituellement en un modèle asymétrique.

Par exemple, pour le premier panel de l'EDTR, la variable la plus importante pour discriminer la réponse et la non-réponse est une variable indiquant si oui ou non une personne est propriétaire d'une maison. Pour les personnes qui sont propriétaires d'une maison, la variable la plus importante significativement pour expliquer la non-réponse est une variable indiquant si oui on non une personne est née soit aux États-Unis, au Royaume-Uni ou au Canada. Pour les personnes qui ne sont pas propriétaires d'une maison, la prochaine variable à être la plus importante significativement pour expliquer la non-réponse est une variable indiquant si oui ou non une personne est âgée de plus de 65 ans (voir figure 3.1 ci-dessous).

Figure 3.1 : Premières branches de l'arbre de décision pour le panel 1, année de référence 1997

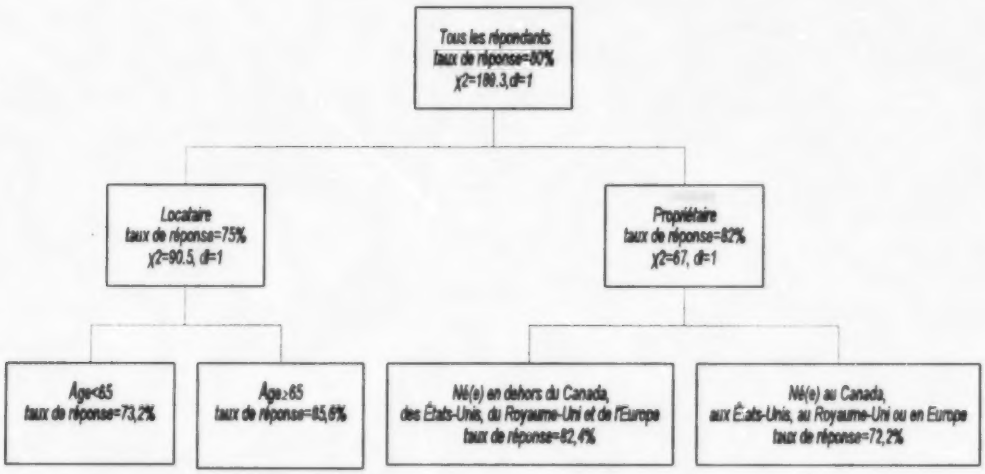

Un autre avantage de la modélisation par segmentation est qu'elle peut être accomplie à l'aide du logiciel Knowledge Seeker; logiciel qui est très convivial, rendant ainsi la tâche de créer un arbre de décision plus facile. Cependant, modéliser par segmentation comporte certains inconvénients. Malgré qu'il est facile de créer un arbre de décision, la prochaine étape dans le processus est lente et fastidieuse puisqu'il faut coder les définitions de tous les RHG dans le programme de pondération longitudinale de l'EDTR pour pouvoir calculer le facteur d'ajustement pour la non-réponse de chaque individu. Le logiciel Knowledge Seeker ne founissant pas de fichier définissant chacun des RHG avec leur taux de réponse associé.

Un autre inconvénient de la modélisation par segmentation est directement relié à l'arbre de désicion lui-même. Lorsqu'un arbre de désicion est formé, il peut facilement devenir assez lourd : dès qu'il comporte plusieurs embranchements, il devient difficile de

l'interpréter. Les arbres de décision sont aussi assez instables; l'ajout, le retrait ou le changement d'une variable ou d'un individu peut avoir un effet important sur l'arbre lui-même. Il est alors très difficile de comparer plusieurs arbres de décision entre eux.

À chaque vague, l'EDTR crée un modèle d'ajustement pour la non-réponse pour chaque panel séparément. Chaque modèle est au départ défini au niveau national. Des embranchements au niveau provincial sont retenus dans l'arbre de décision si ces derniers sont significatifs. L'EDTR utilise un modèle au niveau national puisqu'il est plus pratique et plus facile que de créer un modèle pour chaque province. Une étude faite en 1999 a déterminé que la différence entre l'utilisation d'un modèle national ou de modèles provinciaux est négligeable. Pour plus de détails sur cette étude, se référer à Franklin (1999a).

Pour tenir compte du plan d'échantillonnage, les poids initiaux normés sont utilisés pour calculer une statistique du chi-deux pondérée. Il est à noter que l'EDTR ne fait pas de distinction entre les différents types de non-réponse (non-réponse causée par l'érosion, non-dépisté, refus, etc.). Il est également important de mentionner que certaines contraintes sont appliquées au modèle lors de la modélisation par segmentation chaque GHR doit contenir au moins trente personnes (pondéré et non pondéré) et doit avoir un taux de réponse pondéré d'au moins de 50%. Kalton et Kasprzyk (1986) suggèrent d'avoir de telles contraintes puiqu'elles permettent d'éviter une trop grande variabilité dans les poids et diminuent la perte de précision dans les estimations.

Une fois l'arbre de décision obtenu, les GHR sont formés en considérant chaque extrémité des branches de l'arbre. Les individus qui ont été utilisés pour modéliser la non-réponse (i.e. les adultes répondants ainsi que le adultes non-répondants dans les ménages non-répondants) et les adultes non-répondants qui sont dans un ménage répondant sont alors classés dans les différents GHR. Il est à noter que les adultes non-répondants dans les ménages répondants ne sont pas utilisés lors de la modélisation de la non-réponse même s'ils sont considérés comme répondants puisque dans les faits ils n'ont pas répondu à l'enquête.

L'ajustement pour la non-réponse est fait à l'intérieur de chaque GHR : on divise le poids des répondants d'un GHR par le taux de réponse pondéré observé dans le GHR (ce qui revient à multiplier le poids des répondants par un facteur d'ajustement correspondant à l'inverse du taux de réponse pondéré observé). Pour la cinquième vague du premier panel, 282 GHR ont été formés et avaient un taux moyen de réponse pondéré de 84 %; alors que 134 GHR ont été formés pour la deuxième vague du second panel, avec un taux moyen de réponse pondéré de 88 %.

On obtient les poids corrigés pour la non-réponse en multipliant le poids initial de chaque individu répondant par le facteur d'ajustement pour la non-réponse (ou en divisant par le taux de réponse pondéré observé dans le GHR final). On met le poids des non-répondants à 0 et on garde le poids initial pour les enfants et les individus non-éligibles transversalement.

À chaque vague, les poids longitudinaux ajustés pour la non-réponse sont dérivés de la façon suivante :

$$w_{ajust} = \begin{cases} 0, & \textit{pour les personnes dans les ménages non-répondants} \\ w_{initial}, & \textit{pour les personnes non-éligibles transversalement ou pour les enfants} \\ \dfrac{w_{initial}}{R_{GHR}}, & \textit{pour les personnes dans les ménages répondants} \end{cases}$$

où w_{ajust} = poids longitudinal ajusté pour la non-réponse
$w_{initial}$ = poids longitudinal initial (= $w_{initial,p_1}$ pour le panel 1 ou $w_{initial,p_2}$ pour le panel 2)
R_{GHR} = taux de réponse pondéré observé dans le GHR.

3.4 Ajustement pour les valeurs influentes

Une fois que les poids ont été ajustés pour compenser pour la non-réponse, on procède à l'identification des observations influentes qui ont un impact important sur les estimations ponctuelles du revenu ainsi que sur les estimations de variance. Une valeur est dite influente si elle contribue trop fortement à l'estimation transversale du total des revenus provinciaux. Un facteur d'ajustement entre 0 et 1 est calculé et multiplié aux poids des individus identifiés influents (ainsi que le poids des autres membres de leur ménage) afin de diminuer la contribution des poids de ces individus sur les estimations du revenu. Pour la cinquième vague du premier panel, aucun individu n'a été identifié comme étant influent; et pour la deuxième vague du deuxième panel, seulement deux individus du deuxième panel ont été identifiés comme étant influents.

L'identification des valeurs influentes est seulement effectuée par rapport aux estimations transversales. La même procédure de calcul d'ajustement pour les valeurs influentes pourrait s'appliquer également avec les poids longitudinaux. On obtiendrait ainsi des ajustements pour les valeurs influentes potentiellement différents pour les pondérations transversale et longitudinale. Cependant, des tests faits pour l'année de référence 1995 ont montré qu'à ce moment-là, il n'y aurait pas eu de différence quant aux individus identifiés comme influents, et très peu de différence dans les facteurs d'ajustement comme tels. Il a donc été décidé d'utiliser, pour la pondération longitudinale, les résultats obtenus lors de l'ajustement pour les valeurs influentes du côté transversal. Pour plus de détails sur l'identification des valeurs influentes et sur le calcul du facteur d'ajustement à apporter aux poids, se référer à la section 4.6.

Le poids longitudinal ajusté pour les valeurs influentes est donc défini comme étant :

$$w_{infl} = w_{ajust} * \beta_{infl}$$

où w_{infl} = poids longitudinal après l'ajustement pour les valeurs influentes
w_{ajust} = poids longitudinal ajusté pour la non-réponse
β_{infl} = facteur d'ajustement pour les valeurs influentes ($0 < \beta_{infl} \leq 1$).

3.5 Stratification a posteriori

Le but de la stratification a posteriori (post-stratification) est de faire en sorte que la somme des poids à l'intérieur de certains sous-groupes de l'échantillon (post-strates) corresponde aux totaux de contrôle de la population connus pour ces post-strates, pour une année donnée. La stratification a posteriori est effectuée indépendamment des deux panels. Pour chaque post-strate, la somme des poids avant la stratification a posteriori est calculée. Ensuite, pour chaque post-strate, le total de contrôle de la population est divisé par cette somme de poids. Le poids longitudinal après la stratification a posteriori est alors calculé selon la formule suivante :

$$w_{ps} = w_{infl} * \frac{T_L}{\sum_L w_{infl}}$$

où w_{ps} = poids longitudinal après la stratification a posteriori
w_{infl} = poids longitudinal ajusté pour la non-réponse et les valeurs influentes
T_L = total de contrôle pour la post-strate L

Pour la pondération longitudinale de l'EDTR, les post-strates sont un croisement des trois variables suivantes : province, sexe et groupe d'âge. Les groupes d'âge sont présentés dans le tableau 3.3.

Tableau 3.2 : Groupes d'âge utilisés pour la stratification a posteriori

Groupes d'âge	
Panel 1 (8 groupes d'âge)	**Panel 2 (11 groupes d'âge)**
0-15	0-6
	7-15
16-19	16-18
20-24	19-24
25-34	25-34
35-44	35-44
45-54	45-54
55-64	55-59
	60-64
65+	65-69
	70+

La variable groupe d'âge a subi d'importants changements pour le traitement des données de l'année de référence 1996. Ces modifications ont été apportées aux groupes d'âge du deuxième panel pour faciliter l'intégration de l'EFC à l'EDTR (de façon transversale) et pour

suivre certains standards adoptés par un ensemble d'enquêtes importantes à Statistique Canada. Ainsi à partir de l'année de référence 1996, les nouveaux groupes d'âge devraient être utilisés. Le deuxième panel utilise donc ces groupes d'âge depuis le tout début de son traitement puisqu'il a été sélectionné en 1996. Pour le premier panel, on conserve toujours les anciens groupes d'âge pour effectuer la stratification a posteriori pour assurer une certaine stabilité et ainsi permettre la comparaison entre les différents ensembles de poids produits aux cours des vagues précédant 1996.

Il est important de noter que la province utilisée pour la post-stratification longitudinale est la province habitée par l'individu au moment de la sélection de l'échantillon d'un panel donné, et que le groupe d'âge auquel un individu appartient est déterminé en fonction de son âge toujours au moment de la sélection de l'échantillon du panel concerné. De plus, comme les deux panels ont été sélectionnés à des années différentes, les poids longitudinaux après la stratification a posteriori du premier panel doivent correspondre aux totaux de contrôle pour la population canadienne au 31 décembre 1992 alors que les poids longitudinaux après la stratification a posteriori du deuxième panel doivent être identiques aux totaux de contrôle de la population canadienne du 31 décembre 1995. Ces totaux de contrôle sont obtenus à partir des projections démographiques produites par la Division de la Démographie. Ces données sont seulement disponibles au milieu de chaque mois (et sont donc représentatives de la population des dix provinces canadiennes, avec certaines exclusions, au milieu du mois). L'EDTR utilise les projections démographiques du mois de janvier.

L'ajustement moyen pour la stratification a posteriori apporté aux poids longitudinaux ajusté pour la non-réponse et les valeurs influentes est de 1,11 pour la cinquième vague du premier panel et de 1,10 pour la deuxième vague du second panel.

3.6 Ajout de bruit

Au moment de la production des poids longitudinaux (et transversaux) pour l'année référence 1997, deux fichiers de microdonnées à grande diffusion, un fichier longitudinal et un fichier transversal, devaient être produits annuellement. (Cela n'est plus le cas à partir de l'année de référence 1998.) Par mesure de protection de la confidentialité des données, les fichiers produits ne devaient pas permettre la reconstitution des ménages. Malgré les ajustements décrits dans les sections précédentes, il arrive que des personnes provenant d'un même ménage aient un poids identique, ce qui peut entraîner la reconstitution, même partielle, d'un ménage. Afin d'éviter ceci, il s'est avéré nécessaire, comme dernière étape de la pondération, d'ajouter du bruit aux poids qui apparaîtront sur les fichiers de microdonnées à large diffusion. L'ordre de grandeur du bruit ajouté aux poids peut être établi en fonction de la distribution des différences entre les poids consécutifs, une fois ceux-ci triés en ordre croissant.

L'ajout de la perturbation dans les poids post-stratifiés est effectué selon les étapes suivantes. D'abord, tous les gens en provenance d'un même ménage et avec un poids identique, qu'ils habitent encore ensemble ou non, ont été identifiés. Ensuite, ces gens ont été groupés deux par deux. Dans le cas où un nombre impair de personnes dans un ménage affichaient un poids identique, le poids d'une personne choisie au hasard n'a pas été modifié. Pour chaque paire, une valeur aléatoire e obtenue d'une distribution uniforme U(0,1) a été générée. À cette valeur, on ajoute une valeur a, déterminée de la façon suivante :

$$a = \frac{\max(w_{ps}) \ \min(w_{ps})}{n}$$

où n est la taille d'échantillon et $\max(w_{ps})$ et $\min(w_{ps})$ sont calculés au niveau national. La valeur $e+a$, comprise entre a et $a+1$, a ensuite été ajoutée au poids de la première personne de la paire et soustraite du poids de la deuxième. Ainsi, du bruit est ajouté aux poids et les valeurs identiques qui provenaient d'un même ménage sont éliminées. Les totaux de contrôle pour chaque post-strate sont toujours respectés puisque les individus d'un même ménage qui ont des poids identiques à l'étape de l'ajout de bruit proviennent nécessairement de la même strate, et ont eu les mêmes facteurs d'ajustement pour la non-réponse, pour les valeurs influentes et pour la postratification a posteriori.

Le poids après l'ajout de bruit, que l'on appelle poids externe, est donc obtenu de la façon suivante :

$$w_{bruit} = \begin{cases} w_{ps} \pm (e+a), & \textit{pour les paires d'individus dont le poids est identique à l'intérieur d'un ménage} \\ w_{ps}, & \textit{dans les autres cas} \end{cases}$$

où w_{bruit} = poids longitudinal après l'ajout de bruit
w_{ps} = poids longitudinal après la stratification a posteriori
e = perturbation aléatoire
a = perturbation longitudinale.

Il est à noter que la valeur 1,25 utilisée pour les années références 1995 et 1996 a été réutilisée comme valeur de a pour l'année référence 1997, et ce pour les deux panels. Pour plus de détails, voir Franklin et Lévesque (1999).

3.7 Description des poids longitudinaux finaux produits

Deux ensembles de poids longitudinaux sont produits, appelés poids internes et poids externes. Les poids internes, produits à la fin de la section 3.5, sont utilisés pour des analyses faites à l'intérieur de Statistique Canada et n'ont pas été ajoutés de bruit. Du bruit dans les poids est seulement ajouté aux poids externes puisque ces derniers sont utilisés par les utilisateurs à l'extérieur de Statistique Canada. Ces poids sont produits à la fin de la section 3.6.

Le tableau 3.4 donne les médianes des poids longitudinaux initiaux et finaux par province pour l'année de référence 1997. Seuls les individus avec des poids finaux non nuls sont utilisés dans le calcul de ces médianes. Les poids considérés ici sont les poids internes (i.e. sans ajout de bruit aux poids). La province donnée dans le tableau est la province d'origine (i.e. la province habitée par l'individu au moment de la sélection de l'échantillon du panel dans lequel il appartient).

Tableau 3.3 : Médianes des poids longitudinaux internes (initiaux et finaux), pour la vague 5 du premier panel et la vague 2 du deuxième panel

Province	Panel 1		Panel 2	
	Poids initiaux	Poids finaux	Poids initiaux	Poids finaux
Terre Neuve	207	250	242	285
Île-du-Prince-Édouard	138	164	95	107
Nouvelle-Écosse	237	305	281	322
Nouveau-Brunswick	279	321	254	296
Québec	565	699	566	676
Ontario	563	769	558	718
Manitoba	221	309	327	409
Saskatchewan	305	370	279	347
Alberta	783	870	693	967
Colombie-Britannique	661	848	811	1117

4. Pondération transversale

La présente section donne une description détaillée des étapes nécessaires pour créer un ensemble de poids représentatif de la population des dix provinces canadiennes au 31 décembre d'une année de référence donnée. Tous les individus longitudinaux qui sont dans le champ de l'enquête transversalement et leurs cohabitants sont considérés lors de la production de cet ensemble de poids. La méthodologie présentée dans cette section est celle utilisée pour l'année de référence 1997.

Plusieurs ensembles de poids transversaux sont produits par l'EDTR. Ces ensembles sont composés de poids de type individu ou intégré. Le poids individu peut être différent pour chaque personne à l'intérieur d'un ménage donné tandis que le poids intégré est identique pour chaque individu à l'intérieur d'un même ménage. Le poids intégré est adéquat pour faire des analyses au niveau ménage. Il peut aussi être utilisé pour des analyses au niveau des individus. Quant au poids individu, il permet seulement de faire des analyses au niveau des individus. Certains des ensembles de poids sont produits exclusivement pour fins d'utilisation à l'intérieur de Statistique Canada (poids internes) alors que d'autres sont produits pour les utilisateurs à l'extérieur de Statistique Canada (poids externes). Pour des raisons de confidentialité, du bruit est ajouté à tous les poids externes. Lors de la production des poids transversaux pour l'année de référence 1997, les fichiers de microdonnées à grande diffusion qui devaient être produits ne devaient pas permettre la reconstitution des ménages (par mesure de protection de la confidentialité). En raison de cela, le poids intégré est seulement disponible à l'intérieur de Statistique Canada. Pour les analyses qui doivent être effectuées à l'extérieur de Statistique Canada, le poids individu est utilisé.

En tout, quatre ensembles de poids transversaux sont produits. Le premier ensemble de poids produit est le *poids intégré*, qui rappelons-le est un poids interne. Le deuxième ensemble de poids produit est le *poids individu usuel externe*. Le troisième ensemble de poids produit est le *poids travail interne*. Ce poids est un poids individu similaire au poids individu usuel mais pour lequel la notion de répondant considérée pour produire le poids a été quelque peu modifiée. Pour identifier un répondant, le poids travail ne considère que la réponse à l'interview sur le travail, au lieu d'utiliser la réponse aux deux interviews (interview sur le travail et interview sur le revenu). Par exemple, un ménage non-répondant à l'interview sur le travail (i.e. ménage pour lequel tous ses membres sont non-répondants à cette interview) mais répondant à l'interview sur le revenu (à cause d'une permission donnée préalablement pour utiliser leurs données fiscales) sera pondéré à la pondération individuelle usuelle mais ne le sera pas à la pondération travail. L'utilisation de ce poids, au lieu d'un poids intégré ou d'un poids individu usuel, permet alors d'avoir une meilleure estimation des caractéristiques sur le travail. Le quatrième ensemble de poids produit est le *poids travail externe*.

La pondération transversale s'effectue selon les huit étapes suivantes : la détermination des individus éligibles à la pondération transversale (section 4.1), l'ajustement pour la non-réponse (section 4.2), l'application des facteurs d'allocation des panels (section 4.3), le partage de poids (section 4.4), l'ajustement pour la migration inter-provinciale (section 4.5), l'ajustement pour les valeurs influentes (section 4.6), la stratification a posteriori (section 4.7) et l'ajout de bruit dans les poids (section 4.8). Une description des poids transversaux finaux produits est donnée à la section 4.9.

4.1 Détermination des individus éligibles à la pondération transversale

L'échantillon transversal pour une année donnée est représentatif de la population des dix provinces canadiennes au 31 décembre de l'année de référence (à l'exception des ménages constitués exclusivement d'immigrants). Cet échantillon est composé des individus longitudinaux faisant toujours partie de la population des dix provinces canadiennes au 31 décembre de l'année de référence et des cohabitants de ces personnes. On dit qu'une personne est *éligible transversalement* si elle fait partie de cet échantillon.

Pour déterminer quels individus auront un poids transversal non-nul, il faut d'abord identifier ceux qui sont éligibles transversalement. Tous les individus longitudinaux qui ne font plus partie de la population cible au 31 décembre de l'année de référence (comme les personnes ayant déménagé en dehors des dix provinces canadiennes, les personnes décédées ou en institution) reçoivent un poids transversal nul, même s'ils sont répondants (ou considérés comme répondants). Pour les individus longitudinaux qui font partie de la population cible au 31 décembre de l'année de référence, seuls ceux qui sont dans un ménage répondant ont un poids transversal non nul. Pour la production des poids individus usuels et des poids intégrés, la notion de ménage répondant est la suivante. Un ménage répondant est un ménage dans lequel il y a au moins une personne qui a répondu à au moins une des deux interviews (interview sur le travail, interview sur le revenu). Les personnes non-répondantes dans un ménage répondant auront de l'information imputée. Pour le poids travail, un ménage répondant est un ménage dans lequel il y a au moins une personne qui a répondu à l'interview sur le travail.

4.2 Ajustement pour la non-réponse

Comme mentionné précédemment, l'échantillon transversal pour une année donné est représentatif de la population des dix provinces canadiennes au 31 décembre de l'année de référence. Cependant, comme dans toute enquête, l'EDTR est sujette à la non-réponse (on parle ici de non-réponse totale) et la représentativité de l'échantillon transversal en est alors affectée. Pour réduire l'effet du biais causé par la non-réponse, on ajuste les poids des répondants pour compenser pour les non-répondants.

Du point de vue transversal, on détient trop peu d'information sur les cohabitants non-répondants pour permettre un ajustement pour la non-réponse à ce niveau. En effet, pour plusieurs cohabitants, les seules variables disponibles sont la province, l'âge et le sexe, variables qui seront de toute façon utilisées à l'étape de la stratification a posteriori. Considérant cela, deux méthodes d'ajustement pour la non-réponse au niveau transversal ont été proposées dans le passé (Latouche, Michaud, 1997). La première solution consistait à tout d'abord faire un ajustement pour la non-réponse pour les individus longitudinaux seulement, et à ensuite utiliser la méthode du partage de poids pour attribuer un poids aux cohabitants. De cette manière, les poids des cohabitants sont indirectement ajustés pour la non-réponse. La deuxième alternative consistait à faire un ajustement pour la non-réponse au niveau des ménages en se servant des strates et des groupes de renouvellement des logements initiaux selon le plan de sondage de l'EPA. L'ajustement au niveau des ménages tend toutefois à sous-estimer légèrement les taux de réponse.

La première méthode décrite ci-haut est celle qui a été adoptée par l'enquête. Transversalement, l'étape d'ajustement pour la non-réponse ne relève donc pas de la pondération transversale mais plutôt de la pondération longitudinale. La modélisation et l'ajustement pour la non-réponse longitudinale ont été décrits à la section 3.3. Rappelons tout de même que, pour la pondération longitudinale, chaque panel est traité séparément.

Le poids transversal ajusté pour la non-réponse longitudinale est donc égal au poids w_{ajust} dérivé à la section 3.3. Dénotons par $w_{1997,ajust}$ le poids transversal ajusté pour la non-réponse longitudinale. Ce poids est utilisé comme poids initial pour la production de tous les poids transversaux dérivés (poids individu usuel, poids intégré et poids travail).

4.3 Application des facteurs d'allocation des panels

L'année de référence 1996 était la première année pour laquelle l'EDTR avait deux panels qui se chevauchaient. En théorie les deux panels peuvent être utilisés indépendamment l'un de l'autre pour produire des estimations transversales, mais en pratique il est plus avantageux de combiner les échantillons transversaux des deux panels afin de produire les estimations transversales. La taille d'échantillon est alors doublée, ce qui réduit la variabilité des estimations et offre la possibilité d'utiliser plus de totaux de contrôle lors de l'étape de la stratification a posteriori.

Comme les deux échantillons longitudinaux sont représentatifs de la population des dix provinces canadiennes à des périodes de référence différentes (31 décembre 1992 pour le premier panel et 31 décembre 1995 pour le deuxième panel), il faut trouver un moyen permettant de combiner les deux échantillons pour que ces derniers représentent ensemble la population cible d'une année référence donnée. Le problème qui se pose dans la combinaison des échantillons du premier panel et du deuxième panel est le temps écoulé entre la sélection de ces échantillons. La figure 4.1 présente la dynamique de la population des dix provinces canadiennes entre la sélection des deux panels de l'EDTR.

Figure 4.1 : Dynamique de la population des dix provinces canadiennes entre la sélection des deux panels

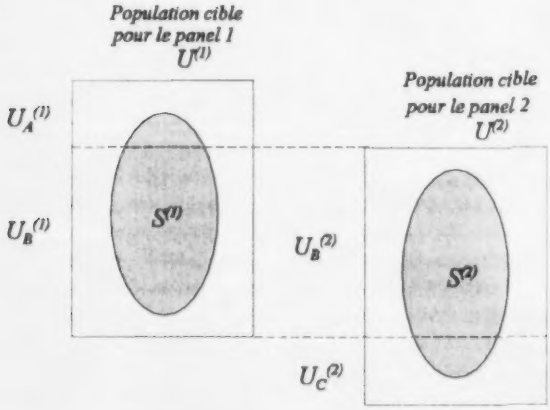

En janvier 1993, on a tiré un échantillon $S^{(1)}$ de la population des dix provinces canadiennes $U^{(1)}$. (Cet échantillon étant l'échantillon longitudinal associé au premier panel). En janvier 1996, un échantillon $S^{(2)}$ a été sélectionné de la population des dix provinces canadiennes $U^{(2)}$ pour former l'échantillon longitudinal du second panel. La majorité des individus dans la population en janvier 1993 sont présents dans la population en janvier 1996 ($U_B^{(1)} = U_B^{(2)}$). Les différences entre les populations $U^{(1)}$ et $U^{(2)}$ sont causées par les personnes qui sont sorties de la population cible entre janvier 1993 et janvier 1996 (personnes décédées, institutionnalisées, personnes ayant déménagé à l'extérieur des provinces, etc.) et par les

nouveaux arrivés dans la population après janvier 1993 (immigrants, naissances). Une partie de l'échantillon du premier panel comprend des personnes de la population sortante entre janvier 1993 et janvier 1996 ($U_A^{(1)}$); les individus de cette population ne font alors plus partie de la population canadienne au moment de la sélection de l'échantillon du deuxième panel et ont ainsi aucune chance d'être choisis. De même, une partie de l'échantillon du second panel est composée de personnes qui sont dans la population des dix provinces canadiennes au moment de la sélection de cet échantillon mais qui n'étaient pas présentes dans la population lors de la sélection du premier panel ($U_C^{(2)}$); ces personnes n'ayant eu aucune chance d'être choisies à ce moment.

Afin de développer une méthode qui permet de combiner l'information des échantillons transversaux des deux panels, il suffit de considérer les deux panels au moment de l'introduction du second panel. La population que l'on doit considérer est $U^{(2)}$, celle effective lors de l'introduction du deuxième panel. Les échantillons longitudinaux à considérer sont les échantillons originaux choisis, l'échantillon du premier panel ayant été réduit à cause des individus qui ont quitté la population et des non-répondants. La méthode développée par Merkouris (1999) est celle que l'EDTR utilise pour jumeler ses échantillons qui se chevauchent (dans le cas présent, les échantillons des panels 1 et 2 sont visés). Soit Y, un paramètre de la population. Pour estimer Y, il s'agit d'utiliser l'estimateur combiné suivant (qui donne une importance relative à chacun des panels selon un certain facteur p) :

$$\hat{Y} = p\hat{Y}_1 + (1-p)\hat{Y}_2$$

où $\hat{Y}$ est l'estimation transversale pour une variable d'intérêt, $\hat{Y}_i$ est l'estimation produite pour cette même variable d'intérêt pour le panel i, et p est le facteur d'allocation des panels. Cet estimateur peut être vu comme une somme pondérée des estimateurs des deux panels où les poids sont les facteurs d'allocation des panels. La valeur optimale du facteur d'allocation des panels a été déterminée de façon à ce que la variance de $\hat{Y}$ soit minimale. Le facteur d'allocation des panels est défini comme suit :

$$p = \left(\frac{n_1}{d_1}\right)\left(\frac{n_1}{d_1} + \frac{n_2}{d_2}\right)^{-1} = \frac{n_1}{n_1 + n_2\left(\frac{d_1}{d_2}\right)} \qquad (4.1)$$

où d_i désigne l'effet de plan d'échantillonnage pour le panel i et n_i représente le nombre de personnes longitudinales de 16 ans et plus du panel i répondantes au temps t (t étant l'année de référence traitée, ici on parle de l'année de référence 1997). L'effet de plan d'échantillonnage est défini comme étant le rapport entre la variance de l'estimation sous-pondérée (i.e. sans étalonnage pour respecter les totaux de contrôle de population) et la variance qui aurait résulté d'un échantillon aléatoire simple de même taille. Pour l'EDTR, le nombre de personnes longitudinales de 16 ans et plus répondantes au temps t correspond au nombre de personnes longitudinales de 16 ans et plus éligibles transversalement qui sont dans un ménage répondant (puisque toutes les personnes dans les ménages répondants sont considérées comme répondantes, voir section 3.2). Même si les cohabitants sont utilisés pour les estimations transversales, seuls les répondants longitudinaux au temps t sont considérés dans le calcul des facteurs d'allocation des panels. Merkouris (1999) et Lavallée (1994) suggèrent de combiner les deux panels avant d'intégrer les cohabitants par la méthode du partage de poids. Omettre les cohabitants dans le calcul

des facteurs p contribue à réduire l'importance du panel le plus âgé, et d'ainsi minimiser les impacts potentiels dus au biais d'attrition.

La détermination d'un facteur p optimal nécessite donc l'estimation d'effets de plan d'échantillonnage et de tailles d'échantillons longitudinaux. Cependant aucun effet de plan n'était disponible pour le deuxième panel au moment du traitement des données. L'EDTR étant un sous-échantillon de l'EPA, il a été décidé d'utiliser les données de l'EPA pour obtenir les effets de plan d'échantillonnage nécessaires pour le calcul des facteurs p. De plus, comme c'est le rapport entre deux effets de plan qui est d'intérêt, l'EPA est tout aussi adéquat pour obtenir les effets de plan désirés. Pour déterminer les effets de plan nécessaires, les six groupes de renouvellement de l'EPA sont utilisés. Ces effets de plan sont calculés pour la caractéristique *nombre de personnes de 15 ans et plus* à l'échelle provinciale (ce qui impliquera le calcul de dix facteurs d'allocation des panels, un par province). Pour la combinaison des premier et deuxième panels, les fichiers de l'EPA de janvier 1993 et de janvier 1996 ont été utilisés pour calculer les effets de plan. Quant aux tailles d'échantillons voulues, elles sont calculées à partir des échantillons longitudinaux des deux panels pour l'année de référence traitée. Comme mentionné précédemment, les tailles d'échantillons désirées sont le nombre de personnes longitudinales de 16 ans et plus répondantes au temps t. On les obtient en considérant toutes les personnes dans les ménages répondants qui ont 16 ans et plus et qui sont éligibles transversalement.

Connaissant les effets de plan et les tailles d'échantillons, il est facile de calculer les facteurs d'allocation des panels d'après l'équation 4.1. Ces facteurs doivent être calculés pour chaque année traitée puisque la composition des échantillons longitudinaux change à chaque année. Pour des raisons pratiques, il a été décidé de calculer les effets de plan à chaque introduction d'un nouveau panel, et d'utiliser ces effets de plan dans le calcul des facteurs d'allocation des panels pour les trois années de chevauchement (Latouche et coll., 2000). Le tableau 4.1 qui suit donne les facteurs d'allocation des panels calculés pour l'année de référence 1997.

Tableau 4.1 : Facteurs d'allocation des panels pour l'année de référence 1997

Province	d_1 / d_2	n_1	n_2	p (Panel 1)	$1 - p$ (Panel 2)
Terre-Neuve	1,71	1693	1306	0,4312	0,5688
Ile-du-Prince-Édouard	1,92	568	883	0,25095	0,74905
Nouvelle-Écosse	4,02	1788	1986	0,18298	0,81702
Nouveau-Brunswick	1,94	1752	1819	0,33176	0,66824
Québec	2,75	4908	5788	0,23568	0,76432
Ontario	2,87	6893	8901	0,21249	0,78751
Manitoba	1,36	1776	2111	0,38219	0,61781
Saskatchewan	2,21	1915	1872	0,31642	0,68358
Alberta	2,87	2378	2113	0,28168	0,71832
Colombie-Britannique	2,76	2238	2509	0,24425	0,75575

d_i = effet de plan d'échantillonnage pour le panel i

n_i = nombre de personnes longitudinales de 16 ans et plus du panel i répondantes pour l'année de référence 1997

p, $1 - p$ = facteurs d'allocation des panels

D'après ce tableau, on constate qu'une plus grande importance est accordée au deuxième panel dans des proportions de 3 pour 1. Lors du dernier remaniement post-censitaire de l'EPA (qui s'est terminé à la fin de 1994), le plan de sondage de l'EPA s'est amélioré; ce qui fait que le rapport d_1 / d_2 est élevé, donnant ainsi une plus grande importance au second panel. Lorsque les deuxième et troisième panels de l'EDTR seront combinés, le rapport des effets de plan seront plus près de 1 puisque les deux panels auront été sélectionnés à partir du même plan de sondage de l'EPA. Les facteurs d'allocation des panels seront donc plus près de 0,5, accordant ainsi une importance similaire aux deux panels.

Les facteurs *p* sont appliqués à toutes les personnes longitudinales du premier panel qui sont dans un ménage répondant au temps t (dans ce cas-ci, au 31 décembre 1997). Les facteurs *1-p* devraient être appliqués à toutes les personnes longitudinales du deuxième panel qui sont dans un ménage répondant au temps t, à l'exception des personnes en dehors de la population cible au moment de l'introduction du premier panel (en janvier 1993) et présents dans la population cible lors de l'introduction du second panel (en janvier 1996). Pour des raisons pratiques, seuls les nouveaux-nés et les immigrants absents lors de l'introduction du premier panel et présents lors de l'introduction du second panel sont exclus lors de l'application des facteurs *1-p*. Les personnes exclues conserveront donc leur poids ajusté pour la non-réponse longitudinale. Ainsi le poids transversal ajusté pour la combinaison des deux panels est le suivant :

$$w_{1997,p} = \begin{cases} p\ w_{1997,ajust'} & \textit{pour les personnes du premier panel} \\ (1-p)\ w_{1997,ajust'} & \textit{pour les personnes du second panel non exclues pour l'application des facteurs d'allocation des panels} \\ w_{1997,ajust'} & \textit{pour les personnes du second panel exclues pour l'application des facteurs d'allocation des panels} \end{cases}$$

où $w_{1997,p}$ = poids transversal ajusté pour la combinaison des deux panels
$w_{1997,ajust}$ = poids transversal ajusté pour la non-réponse longitudinale
p = facteur d'allocation des panels.

Ce poids est identique pour les poids transversaux individu usuel et intégré. Pour le poids transversal travail, le poids ajusté pour la combinaison des panels est calculé de la même façon mais où la notion de ménage répondant a été changée (section 4.1). Il est à noter que les facteurs d'allocation des panels sont appliqués aux poids après l'étape d'ajustement pour la non-réponse mais avant l'étape du partage de poids, pour que ces facteurs soient aussi inclus dans le poids des cohabitants.

4.4 Partage des poids

L'étape du partage des poids est essentielle et unique à la pondération transversale. Elle est engendrée par la nature longitudinale de l'EDTR. Dans une enquête longitudinale, l'échantillon évolue à travers le temps. De nouvelles personnes viennent habiter avec les individus déjà sélectionnés, des enfants naissent dans certains ménages échantillonnés. Bref, d'autres personnes qui n'ont pas été échantillonnées initialement font désormais partie de l'échantillon. Puisqu'on ne connaît pas la probabilité de sélection des personnes qui se sont jointes à l'enquête (les cohabitants), il faut trouver une façon de leur assigner un poids. Cela est fait en utilisant la méthode du partage des poids. Les prochains paragraphes

expliquent brièvement la méthodologie du partage des poids. Pour plus de détails sur la méthode du partage des poids, l'article de Lavallée (1995) est recommandé.

À partir de l'étape du partage de poids, on ne fait plus de distinction entre les deux panels et on traite tous les individus comme faisant partie d'un même échantillon, tout en conservant les notions d'individu longitudinal et de cohabitant. On pourrait penser qu'en choisissant d'effectuer le partage de poids au niveau du ménage, traiter les deux échantillons transversaux de façon individuelle ou de façon combinée reviendrait au même. Or il faut penser qu'en présence d'une enquête à panels multiples se chevauchant, il est possible d'observer des ménages pour lesquels des personnes issues du premier panel cohabitent avec des personnes issues du second panel. Lors de l'introduction du deuxième panel, tout ménage sélectionné pour faire parti de l'échantillon longitudinal comportant au moins une personne longitudinale du premier panel a été exclue de l'échantillon longitudinal du second panel afin de ne pas enquêter le ménage pour une autre période de six ans. Cependant, étant donné la nature longitudinale et dynamique de l'enquête, il se peut qu'au cours des six années, des ménages se séparent et de nouveaux ménages se forment, rendant ainsi possible le fait d'observer un ménage composé de personnes provenant des deux panels. En considérant les échantillons transversaux séparément, deux ensembles de poids distincts seraient produits pour ces ménages; ce qui causerait toutes sortes de problèmes. Il est alors préférable de considérer les deux panels ensemble.

Pour effectuer le partage des poids, il faut d'abord déterminer à quel niveau dans la hiérarchie du plan de sondage on veut l'effectuer : au niveau de la province, de la strate, de l'unité primaire d'échantillonnage ou de l'unité finale d'échantillonnage. L'EDTR a choisi d'effectuer le partage des poids au niveau de l'unité finale d'échantillonnage, le ménage. Une fois cela décidé, il s'agit de déterminer le statut de chaque personne dans l'échantillon transversal, selon que la personne est un individu longitudinal, un cohabitant initialement présent ou un cohabitant initialement absent.

Un cohabitant est initialement présent s'il faisait partie de la population cible au moment de la sélection du deuxième panel (en janvier 1996). À l'inverse, un cohabitant est initialement absent s'il ne faisait pas partie de la population cible au moment de la sélection du deuxième panel (en janvier 1996). Étant donné qu'on traite ici le chevauchement de deux panels, les notions de cohabitant initialement absent et initialement présent doivent tenir compte du fait qu'on ne traite plus qu'un seul panel et qu'on doit traiter les deux panels ensemble. On doit alors considérer les deux panels au moment de la sélection du deuxième panel (en janvier 1996). Il est important de mentionner que tous les cohabitants de l'enquête ont un poids longitudinal de zéro étant donné qu'ils ne faisaient pas partie de l'échantillon longitudinal. Par contre, ils peuvent avoir un poids transversal différent de zéro qui leur est assigné par la méthode du partage des poids.

À l'étape du partage de poids, deux types de poids sont produits pour chaque individu : le poids individu (qui peut être différent pour chaque personne à l'intérieur d'un ménage donné), et le poids intégré (poids identique pour tous les membres d'un même ménage).

Dans le cas du partage des poids pour le poids individu, il faut procéder selon les étapes suivantes. D'abord, il faut identifier les ménages auxquels des cohabitants se sont greffés depuis la sélection de l'échantillon longitudinal. Pour les ménages composés exclusivement de personnes longitudinales, il n'est pas nécessaire d'appliquer la méthode du partage des poids. Par conséquent, pour tous les individus de ces ménages, le poids transversal partagé est identique au poids transversal ajusté après l'application des facteurs d'allocation des panels.

Ensuite, pour les ménages où des cohabitants sont arrivés, il s'agit de faire la somme des poids transversaux ajustés pour la non-réponse $w_{1997,p}$ de tous les individus longitudinaux à l'intérieur du ménage. Puis, il faut établir le nombre d'individus longitudinaux et le nombre de cohabitants initialement présents dans chaque ménage.

Pour les ménages où au moins un des cohabitants est initialement présent, le poids transversal partagé de tous les individus d'un ménage donné est calculé comme étant la somme des poids transversaux $w_{1997,p}$ de tous les individus longitudinaux du ménage divisé par le nombre total d'individus longitudinaux et de cohabitants initialement présents dans le ménage.

Pour les ménages où tous les cohabitants sont initialement absents, le poids transversal partagé des individus longitudinaux et des cohabitants est calculé différemment. Pour les individus longitudinaux faisant partie de ces ménages, le poids transversal partagé est égal au poids transversal ajusté après l'application des facteurs d'allocation des panels. Pour les cohabitants, le poids transversal partagé est égal à la somme des poids $w_{1997,p}$ de tous les individus longitudinaux du ménage divisé par le nombre total d'individus longitudinaux. De cette façon, un poids moyen ne sera pas assigné aux individus longitudinaux et l'ajustement pour la non-réponse sera préservé. Seuls les individus initialement absents recevront le poids moyen des individus longitudinaux du ménage.

Le poids transversal individu partagé (poids individu usuel ou poids travail) est alors défini comme étant :

$$w_{1997,part} = \begin{cases} w_{1997,p}, & \textit{pour les personnes dans les mén. composés exclusivement de personnes longitudinales et pour les personnes longitudinales dans les ménages où tous les cohabitants sont IA} \\ \dfrac{\sum_{h} w_{1997,p}}{n_{L,h} + n_{IP,h}}, & \textit{pour les personnes dans les ménages ayant au moins un cohabitant IP et pour les cohabitants dans les ménages où tous les cohabitants sont IA} \end{cases}$$

où $w_{1997,part}$ = poids transversal partagé
$w_{1997,p}$ = poids transversal ajusté pour la combinaison des deux panels
IP = initialement présent
IA = initialement absent
$n_{L,h}$ = nombre de personnes longitudinales dans le ménage h
$n_{IP,h}$ = nombre de cohabitants initialement présents dans le ménage h.

Dans le cas du partage des poids pour le poids intégré, le processus est quelque peu différent. Tout individu qui aura un poids transversal individu non nul (poids individu usuel seulement) aura tout de même un poids transversal intégré non nul. Ceci est rendu nécessaire par le fait que le poids avant stratification a posteriori doit être identique pour tous les gens d'un ménage afin de pouvoir produire un poids intégré (Lemaître, Dufour, 1987). La différence entre les poids intégrés et les poids individu provient du fait qu'il faut effectuer le partage sur tous les ménages, peu importe que des cohabitants s'y trouvent ou non. Par conséquent, pour tous les ménages, le poids partagé est calculé de la même façon pour tous les individus lorsque le poids produit est intégré. Le poids transversal partagé intégré est donc défini comme étant :

$$w_{1997,part} = \frac{\sum_h w_{1997,p}}{n_{L,h} + n_{IP,h}}$$

où $w_{1997,part}$ = poids transversal partagé
$w_{1997,p}$ = poids transversal ajusté après la combinaison des deux panels
$n_{L,h}$ = nombre de personnes longitudinales dans le ménage h
$n_{IP,h}$ = nombre de cohabitants initialement présents dans le ménage h.

Pour l'année de référence 1997, un total de 80 834 personnes font partie de l'échantillon transversal. Ce nombre comprend les personnes répondantes et non-répondantes (pour les ménages non-répondants, on utilise la dernière composition connue de ces ménages). Il est sous-représentatif du nombre réel de personnes dans l'échantillon transversal puisque pour les ménages non-répondants, on a aucune information sur la composition actuelle des ménages. Parmi les 80 834 personnes, 79 218 ont des poids transversaux individu usuel et intégré non nuls et 76 421 ont un poids transversal travail non nul.

4.5 Ajustement pour la migration inter-provinciale

L'étape de l'ajustement pour la migration inter-provinciale est une autre étape directement engendrée par la nature longitudinale de l'EDTR. À travers les années, il arrive que certaines personnes échantillonnées déménagent d'une province à une autre. Étant donné que la probabilité de sélection peut varier beaucoup selon la géographie, un grand écart est observé, à l'échelle canadienne, entre les poids les plus grands et les poids les plus petits. Par conséquent, si une personne avec une probabilité de sélection assez faible (donc un poids assez grand) déménage dans un endroit où la probabilité de sélection des gens est beaucoup plus forte (donc des poids beaucoup plus petits), il y a potentiellement matière à problème. En effet, du point de vue analytique, les résultats d'analyse peuvent se trouver faussés à cause de certains cas de migration inter-provinciale.

Pour expliquer le problème, prenons un exemple simple. Supposons qu'un chirurgien cardiaque déménage de Toronto à Charlottetown. Cette situation causerait plusieurs problèmes. D'abord, son poids qui s'établirait aux environs de 400 serait beaucoup plus grand que tous les poids que l'on retrouve à l'Île-du-Prince-Édouard et qui sont en moyenne aux environs de 65 À lui seul, il représenterait tout à coup environ 3.33% de la population de la province, soit environ 5000 personnes sur 150 000, ce qui est totalement inadmissible. Ensuite, du point de vue analytique, il viendrait artificiellement augmenter le revenu total des gens à cause de son poids de 5000 et de son salaire.

Plusieurs options sont envisageables pour atténuer le problème de poids aberrants causés par la migration inter-provinciale. Ces poids extrêmes pourraient être remplacés par le poids moyen, la médiane ou un des quantiles de la distribution des poids des personnes de la province où les gens déménagent, ou toute autre possibilité basée sur cette distribution. Ces alternatives sont arbitraires et pourraient toutes être utilisées. Il s'agit en fait de trouver un compromis entre le fait d'attribuer à la personne migrante un poids similaire à la moyenne des poids des personnes de sa province de destination et le fait de ne pas trop modifier son poids d'origine (basé sur la probabilité de sélection). L'objectif ici est tout d'abord d'identifier les personnes qui ont migré dans une autre province dont leur poids contribue trop fortement à l'estimation de leur province de destination, et ensuite d'ajuster ce poids.

L'EDTR a adoptée une méthode utilisant le 95e percentile de la distribution des poids. Cette méthode a l'avantage d'être simple, rapide et de ne pas nécessiter d'intervention manuelle (ou presque). Il s'agit tout d'abord d'identifier toutes les personnes qui ont déménagé dans une province particulière dont leur poids est plus grand que le maximum des poids des personnes originaires de cette province. Si c'est le cas, le poids de ces personnes est ramené au 95e percentile de la distribution des poids des personnes originaires de la province. Ensuite un nombre aléatoire entre 0.00 et 10.00 est soustrait de ce percentile afin de conserver la "presque" unicité des poids (il est possible d'avoir des poids individus égaux mais cela est très rare).

Les ajustements pour la migration inter-provinciale sont effectués indépendamment pour les poids individus et intégrés et sont redérivés à chaque année de traitement. Pour le poids intégré, l'ajustement est fait au niveau ménage afin de préserver l'égalité des poids à l'intérieur d'un ménage. Le poids transversal ajusté pour la migration inter-provinciale est définit comme étant :

$$w_{1997,mig} = w_{1997,part} * a_{mig}$$

où $w_{1997,mig}$ = poids transversal ajusté pour la migration inter-provinciale
$w_{1997,part}$ = poids transversal partagé
a_{mig} = facteur d'ajustement pour la migration inter-provinciale.

Pour l'année de référence 1997, un ajustement de migration inter-provinciale s'est avéré nécessaire pour 36 personnes pour le poids transversal individu usuel, pour 15 ménages (43 personnes) pour le poids transversal intégré et pour 34 personnes pour le poids transversal travail.

4.6 Ajustement pour les valeurs influentes

Comme toute enquête essayant d'estimer la distribution des revenus des gens, l'EDTR est vraisemblablement confrontée au problème des observations influentes (ces distributions ayant de très longues queues). Les observations influentes ont un impact important sur les estimations provinciales du total et de la moyenne du revenu ainsi que sur leurs estimations de variance. L'impact devient encore plus accentué sur les estimations de plus petits domaines comme les estimations selon le groupe d'âge, le sexe ou la taille des familles. Pour diminuer l'effet de ces observations sur les estimations, il faut d'abord trouver un moyen d'identifier ces observations, puis de développer une méthode pour ajuster ces observations de telle sorte qu'elle permette de réduire l'influence de celles-ci sur les estimations.

Il est à noter que les étapes d'identification des observations influentes et de calcul des facteurs d'ajustement sont faites sur les poids individus seulement (poids individus usuels ou poids travail), mais que les facteurs d'ajustement dérivés sont appliqués aussi bien sur les poids individus que sur les poids intégrés.

Une méthode de détection et de traitement des valeurs influentes a été mise sur pied par l'EFC (Tremblay, 1998). Comme on savait que l'EFC serait intégrée à l'EDTR à la collecte de 1999, la méthodologie développée tient compte du fait que l'enquête qui remplacerait l'EFC est de nature longitudinale. Cette approche a donc été adoptée par l'EDTR pour

traiter le problème des revenus influents. La méthode consiste d'abord à identifier les observations influentes, c'est-à-dire celles qui contribuent trop fortement à l'estimation pondérée du total des revenus individuels de sa province. Il s'agit en général d'observations qui se trouvent dans une tranche de revenu élevé. Le revenu d'un individu (on parle ici du revenu total moins les gains en capital) est considéré comme influent si la contribution de son revenu pondéré par rapport à l'estimation pondérée provinciale dépasse un certain seuil. Ce seuil correspond à la borne inférieure de l'intervalle calculée à partir de la méthode des quartiles. Il se définit comme étant MED + k (Q3 - MED), où MED et Q3 sont respectivement la médiane et le troisième quartile de la contribution pondérée des individus, et k est un paramètre fixe pour chaque province qui a été déterminé après avoir examiné les observations ayant les pourcentages de contribution les plus élevés à l'estimation provinciale. (La valeur de k est de 25 pour toutes les provinces, exceptés pour le Québec et l'Ontario où k est égal à 75.)

Une fois que les observations influentes sont identifiées, il faut maintenant déterminer les facteurs d'ajustement applicables aux poids associés à ces observations. Pour ce faire, on évalue si l'échantillon surreprésente les revenus supérieurs à 99 999$ par rapport à la distribution des revenus de la population des déclarants de données fiscales (distribution obtenue du fichier T1 de Revenu Canada). Si c'est le cas, le poids est ajusté de sorte que la distribution de l'échantillon pondéré coïncide avec celle des données fiscales sauf dans le cas où cette différence est faible (ce qui vise à maintenir au minimum les ajustements de poids). L'ajustement de ce poids se fait en calculant un certain facteur d'ajustement, ce facteur sera compris entre 0 et 1. Plus précisément, voici comment le calcul du facteur d'ajustement est effectué pour chaque individu ayant un revenu influent. Notons que ces calculs sont faits au niveau provincial.

> "*Si une province contient plus d'un individu influent, le facteur d'ajustement est d'abord calculé pour l'individu influent avec le revenu (non pondéré) le plus élevé. Supposons que cet individu est dans la classe de revenu c. L'ajustement fera en sorte que l'estimation du nombre d'individus qui se trouve dans la classe c ou dans toute autre classe de revenu supérieure, soit égale au nombre d'individus dans ces mêmes classes sur le fichier de données fiscales, sujet toutefois à certaines contraintes. D'abord, uniquement les poids des individus influents devront être modifiés dans cet ajustement. De plus, si l'ajustement entraîne une hausse du poids, c'est-à-dire que le facteur d'ajustement est supérieur à 1, l'ajustement ne sera pas appliqué et le poids initial sera conservé. Si le fichier de données fiscales indique qu'il n'y a aucun individu dans les classes de revenu, l'ajustement ramènera le poids à 1. De la même façon, on ramènera le poids à 1 si le nombre d'individus estimés dans ces classes à partir des individus non influents seulement, dépasse déjà le nombre d'individus selon le fichier de données fiscales.*" (Tremblay, 1998).

Le calcul du facteur d'ajustement est dépendant d'un individu à l'autre. Lorsque le facteur d'ajustement a été calculé pour l'individu influent avec le plus haut revenu, c'est le poids ajusté de cet individu qui sera considéré dans le calcul du facteur d'ajustement de l'individu suivant.

Bien que le facteur d'ajustement soit calculé au niveau de l'individu, il devra être appliqué au poids de le personne identifiée comme influente ainsi qu'aux poids de toutes les autres personnes habitant le même ménage qu'elle et ce, pour le reste de la durée du panel même si cette personne n'est plus considérée influente dans les vagues subséquentes à celle où elle a été identifiée. L'aspect longitudinal de l'enquête entraîne cette procédure afin de préserver la cohérence à travers les années, même dans le contexte de la pondération transversale. Pour les ménages où aucun individu n'a été traité pour la valeur extrême de son revenu, le facteur d'ajustement est de 1 pour tous les membres de ces ménages.

Afin de détecter les valeurs influentes, la méthode utilise le poids obtenu après la stratification a posteriori (dont il est question à la section suivante) puisque cette dernière repose sur la distribution des revenus de la population. Il faut donc faire une stratification a posteriori temporaire avant d'effectuer l'étape de l'ajustement pour les valeurs influentes, puis utiliser les poids temporaires post-stratifiés pour identifier et traiter les observations influentes. Une fois les facteurs d'ajustement calculés, la stratification a posteriori doit être refaite en appliquant ces facteurs aux poids que l'on avait avant cette stratification a posteriori temporaire (donc aux poids transversaux ajustés pour la migration inter-provinciale $w_{1997,mig}$).

Le poids transversal après ajustement pour les valeurs influentes est donc calculé comme suit :

$$w_{1997,infl} = w_{1997,mig} * \beta_{infl}$$

où $w_{1997,infl}$ = poids transversal ajusté pour les valeurs influentes
$w_{1997,mig}$ = poids transversal ajusté pour la migration inter-provinciale
β_{infl} = facteur d'ajustement pour les valeurs influentes.

Pour l'année de référence 1997, deux personnes ont été identifiées comme ayant des revenus influents. De plus, les poids de sept autres personnes identifiées comme étant influentes lors des vagues précédentes doivent à nouveau être ajustés. En incluant les individus qui habitent avec toutes ces personnes, l'ajustement pour les valeurs influentes a été appliqué à un total de 29 personnes pour l'année de référence 1997. Les facteurs d'ajustement apportés aux poids de ces personnes variaient de 0,39 à 0,93, la plupart des facteurs étant autour de 0,50.

4.7 Stratification a posteriori

Rappelons que le but de la stratification a posteriori (ou post-stratification) est de faire en sorte que la somme des poids à l'intérieur de certains sous-groupes de l'échantillon (les post-strates) corresponde aux totaux de contrôle de la population connus pour ces post-strates, pour une année donnée.

Pour les poids transversaux individus, la stratification a posteriori est accomplie de la même manière que celle effectuée par la pondération longitudinale (section 3.5). Le poids après la stratification a posteriori est égal au poids avant la stratification a posteriori, multiplié par le total de contrôle de la population de la post-strate à laquelle l'individu appartient, divisé par la somme des poids avant la stratification a posteriori de cette post-strate.

Pour produire le poids intégré, la méthodologie est un peu plus complexe. Tout en respectant les totaux de contrôle pour chaque post-strate, la stratification a posteriori doit aussi s'assurer que tous les individus d'un même ménage ont le même poids final. Pour plus d'informations sur la façon de procéder, l'article de Lemaître et Dufour (1987) se veut la référence en la matière. Notons par $w_{1997,ps}$, le poids transversal après la stratification a posteriori.

Comme pour la pondération longitudinale, les post-strates pour la pondération transversale sont un croisement des trois variables suivantes : province, sexe et groupe d'âge. La province fait référence ici à la province de résidence au 31 décembre de l'année de

référence. De même, le groupe d'âge auquel un individu appartient est déterminé en fonction de son âge au 31 décembre de l'année de référence. Les valeurs possibles pour le groupe d'âge sont celles présentées précédemment dans le tableau 3.2.

Pour l'année de référence 1997, les poids transversaux individus usuels après l'ajustement pour les valeurs influentes ont été en moyenne multipliés par 1,13 pour permettre le redressement de l'échantillon de l'EDTR. Les poids transversaux intégrés ont aussi été multipliés en moyenne par 1,13 lors de la stratification a posteriori. Pour la pondération travail, un ajustement moyen de 1,18 a été apporté aux poids transversaux travail pour effectuer le redressement de l'échantillon.

4.8 Ajout de bruit

Comme pour le poids longitudinal, une étape d'ajout de bruit a été ajoutée pour des raisons de confidentialité. Il est important de mentionner que dans le cas de la pondération transversale, l'ajout de bruit s'applique seulement au poids individu et non au poids intégré. En effet, la présence d'un poids intégré sur le fichier de microdonnées à grande diffusion serait contraire à l'objectif d'éviter la reconstitution des ménages à partir de ce fichier. Par conséquent, seul le poids individu sera perturbé et inclut sur le fichier de microdonnées à grande diffusion.

L'ajout de bruit dans les poids transversaux individus est effectué selon les mêmes étapes que celles de la pondération longitudinale (voir section 3.6). La perturbation aléatoire e, comprise entre 0 et 1, et la perturbation a (perturbation transversale) introduites dans les poids transversaux individus sont déterminées de la même façon que pour les poids longitudinaux. Le poids transversal individu après l'ajout de bruit est obtenu de la façon suivante :

$$w_{bruit} = \begin{cases} w_{ps} \pm (e \cdot a), & \textit{pour les paires d'individus dont le poids est identique à l'intérieur d'un ménage} \\ w_{ps}, & \textit{dans les autres cas} \end{cases}$$

où w_{bruit} = poids transversal après l'ajout de bruit
w_{ps} = poids transversal après la stratification a posteriori
e = perturbation aléatoire
a = perturbation transversale.

Pour l'année référence 1997, le facteur a des années références 1995 et 1996, qui était égal à 1, a été réutilisé pour les poids individu usuel. Pour le poids travail, un facteur a de 1,25 a été utilisé.

4.9 Description des poids transversaux finaux produits

La pondération transversale produit quatre ensembles de poids transversaux différents, un poids intégré et trois différents poids individus : le poids individu usuel externe, le poids travail interne et le poids travail externe. Le poids intégré et le poids travail interne sont produits à la fin de l'étape de la stratification a posteriori (section 4.7), alors que le poids individu usuel externe et le poids travail externe sont produits à la fin de l'étape de l'ajout

de bruit dans les poids (section 4.8). Le tableau 4.3 donne les médianes des poids transversaux initiaux de certains poids transversaux finaux, pour l'années de référence 1997. Seuls les individus avec des poids finaux non nuls sont utilisés dans le calcul de ces médianes. La province donnée dans le tableau fait référence à la province de résidence au 31 décembre 1997.

Tableau 4.2 : Médianes des poids transversaux initiaux et finaux, pour l'année de référence 1997

Province	Poids initiaux	Poids finaux		
		Poids intégré	Poids individu usuel externe	Poids travail interne
Terre Neuve	133	127	129	133
Île-du-Prince-Édouard	71	71	75	77
Nouvelle-Écosse	105	113	113	117
Nouveau-Brunswick	150	150	155	159
Québec	270	309	309	318
Ontario	253	301	302	314
Manitoba	148	167	171	180
Saskatchewan	161	163	165	170
Alberta	261	303	302	316
Colombie-Britannique	305	421	411	426

5. Changements à venir et développements futurs

Afin d'améliorer la qualité et la fiabilité des estimations, les étapes de pondérations longitudinale et transversale de l'EDTR sont régulièrement révisées. Ces révisions sont effectuées en tenant compte de toute modification ayant trait aux objectifs, au traitement et à la diffusion.

Un des changements à venir concerne la stratégie de diffusion des microdonnées de l'EDTR. Avant l'intégration de l'EFC à l'EDTR (comme c'est le cas pour l'année de référence 1997), la stratégie de diffusion consistait à produire annuellement un ensemble de fichiers transversaux et longitudinaux de microdonnées à grande diffusion pour lesquels la reconstitution des ménages au sein de ces fichiers n'étaient pas possible. En raison de l'intégration de l'EFC à l'EDTR, il est maintenant devenu une priorité de diffuser des fichiers transversaux qui satisfont les besoins des utilisateurs de l'EFC. Pour ce faire, le contenu des fichiers de microdonnées transversaux à grande diffusion doit être redéfini et doit inclure des identificateurs de ménage et de famille pour permettre la reconstitution des ménages et des familles.

La diffusion de tels fichiers transversaux remets en question la diffusion de fichiers de microdonnées longitudinales à grande diffusion. On pense que le risque de divulgation associé aux fichiers longitudinaux permettant la reconstitution des ménages et des familles serait trop élevé, et qu'il serait probablement difficile de créer des fichiers longitudinaux pour lesquels le risque d'appariement avec les fichiers transversaux serait bas. Pour des raisons prioritaires, il a été décidé de se concentrer sur la stratégie de diffusion des fichiers de microdonnées transversales et de considérer d'autres possibilités pour rendre les données longitudinales disponibles aux utilisateurs à l'extérieur de Statistique Canada. Parmi ces possibilités, il y a le télé-accès des données et le centre d'accès aux données de recherche. Pour plus de renseignements sur la stratégie de contrôle de la divulgation des microdonnées, se référer à l'article de Nadeau, Gagnon et Latouche (1999).
Comme la diffusion d'un fichier de microdonnées longitudinales à grande diffusion est dorénavant compromise, le production du poids longitudinal externe ne semble plus nécessaire. De plus, avec la nouvelle stratégie de diffusion permettant la reconstitution des ménages et des familles à partir des fichiers transversaux, le poids transversal individu externe n'est plus utile. Pour l'instant, ces deux poids sont toujours produits mais l'abolition de ces derniers sera discutée dans un proche avenir.

Un autre changement qui sera apporté à l'enquête est l'implantation de l'imputation des données sur le travail principalement pour les personnes non-répondantes à l'interview sur le travail mais répondante à l'interview sur le revenu. Avant l'intégration de l'EFC à l'EDTR, les fichiers diffusés pouvaient comporter des données manquantes pour les caractéristiques du travail. Avec l'intégration de l'EFC à l'EDTR, on veut maintenant fournir des fichiers de microdonnées complets, sans aucune donnée manquante. Considérant cela, l'utilité du poids travail est remise en question. La non-réponse à l'interview sur le travail étant maintenant compensée en imputant les données, on ne verrait plus l'utilité de produire un poids travail qui compense pour la non-réponse en ne considérant dans la pondération que les répondants à l'interview sur le travail. Le poids travail est toujours produit, mais une fois que toutes les procédures d'imputation des données sur le travail seront en place, l'élimination de ce poids sera considérée plus sérieusement.

Un changement au niveau du redressement de l'échantillon transversal est aussi prévu. L'EDTR révise présentement sa stratégie de redressement de l'échantillon dans le but d'améliorer les estimations et d'harmoniser les concepts entre les différentes enquêtes-ménages. Jusqu'à maintenant, l'EDTR utilise des totaux de contrôle au niveau de la province, du groupe d'âge et du sexe pour effectuer le redressement de son échantillon

transversal. Des nouveaux ensembles de totaux de contrôle sont envisagés : le nombre de familles économiques de taille 1, 2 et 3 et plus par province, et le niveau de revenu (bas, moyen, élevé) par province.

De tels ajouts remettent en question la définition des ensembles de totaux de contrôle utilisés jusqu'à maintenant, plus particulièrement au niveau des catégories de groupe d'âge. L'ajout de ces nouveaux ensembles de totaux entraîne aussi la modification de la méthode utilisée pour effectuer le redressement de l'échantillon : la stratification a posteriori devra être remplacée par un calage sur marges. L'équipe de méthodologie de l'EDTR révise présentement sa stratégie pour permettre d'intégrer facilement ces nouveaux totaux à la méthode déjà en place pour effectuer le redressement de l'échantillon transversal. L'impact d'un tel changement sur les poids sera aussi étudié en profondeur.

Au niveau de la pondération longitudinale, une des nouveautés à venir est la production d'un poids qui combinerait les deux panels de l'EDTR. Le défit ici sera de définir la population longitudinale pour plusieurs panels. Actuellement, la pondération longitudinale considère les deux panels de façon indépendante, produisant des poids pour chacun des panels indépendamment l'un de l'autre. Le calcul d'un poids longitudinal qui utiliserait les répondants des deux panels permettrait d'accroître la précision des estimations lors d'analyses longitudinales (puisque la taille d'échantillon serait alors doublée). Pour produire un tel poids, on s'inspirera de la méthode utilisée pour combiner les échantillons transversaux de l'EDTR.

6. Conclusion

L'objectif de l'EDTR de fournir des données longitudinales et transversales pour plusieurs caractéristiques reliées à la dynamique du travail et du revenu, qui sont représentatives de la population des dix provinces canadiennes, est un grand défi. Les pondérations longitudinale et transversale expliquées en détails dans ce document permettent de produire des poids longitudinaux et transversaux nécessaires à ces fins. Pour produire ces poids, plusieurs étapes sont requises : la détermination des poids initiaux, l'ajustement pour la non-réponse, le partage des poids (seulement pour les poids transversaux), les ajustements pour la migration inter-provinciale (seulement pour les poids transversaux) et les valeurs influentes, la stratification a posteriori et l'ajout de bruit dans les poids. Au fil des ans, ces étapes ont été améliorées et optimisées mais avec l'évolution des stratégies de traitement et de diffusion, de nouvelles mises au point sont nécessaires pour entre autre préserver la qualité et la fiabilité des données. Par exemple, l'ajout de nouvelles post-strates pour le redressement de l'échantillon transversal, la production d'un poids longitudinal qui combine les deux panels et le changement dans la stratégie de diffusion qui remettra en question l'utilité de certains poids longitudinaux et transversaux.

Remerciements

Les auteurs tiennent tout d'abord à remercier Christian Nadeau pour son support et ses précieux conseils tout au long de la rédaction de ce document. Ils tiennent également à remercier Michel Latouche, Guy Laflamme et Martin St-Pierre pour leurs commentaires qui ont permis d'améliorer la qualité de ce document.

Bibliographie

Cotton, C., Bishop, K., Giles, P., Hewer, P. et Saint-Pierre, Y. (1999). *Comparaison des résultats de l'Enquête sur la dynamique du travail et du revenu (EDTR) et de l'Enquête sur les finances des consommateurs (EFC) 1993-1997 : mise à jour*, publication de Statistique Canada N°75F0002MIF - 99007.

Dufour, J., Gagnon, F., Morin, Y., Renaud, M. et Särndal, C.E. (1998). *Measuring the Impact of Alternative Weighting Schemes for Longitudinal Data* , Proceedings of the Survey Research Methods Section, American Statistical Association.

Durning, A. (1994). *Weighting of the SLID Preliminary File*, document interne, Statistique Canada.

Franklin, S. (1999a). *Modelling SLID's Nonresponse at the Provincial Level*, document interne, Statistique Canada.

Franklin, S. (1999b). *Study of the Impact of Modifying SLID's Nonresponse Model*, document interne, Statistique Canada.

Franklin, S. et Lévesque, I. (1999). *L'ajout de bruit aux poids post-stratifiés*, document interne, Statistique Canada.

Gagnon, F. (1997). *Pondération longitudinale - Deuxième vague de l'EDTR* , document interne, Statistique Canada.

Gambino, J.G., Singh, M.P., Dufour, J., Kennedy, B. et Lindeyer, J. (1998). *Méthodologie de l'enquête sur la population active du Canada*, Statistique Canada, Catalogue 71-526-XPB.

Grondin, C. (1996). *Pondération longitudinale - Première vague de l'EDTR* , document interne, Statistique Canada.

Kalton, G. et Kasprzyk, D. (1986). *Le traitement des données d'enquête manquantes*, Techniques d'enquête, vol. 12, no 1, pp. 1-17.

Knowledge SEEKER IV, Version 4.2.2, Copyright 1996, Angoss International Limited.

Latouche, M., Dufour, J. et Merkouris, T. (2000). *SLID Cross-Sectional Weighting: Combining Two or More Panels*, document interne à paraître, Statistique Canada.

Latouche, M. et Michaud, S. (1997). *Concerns pertaining to weighting of longitudinal surveys*, Proceedings of the Section on Government Statistics and Section on Social Statistics, American Statistical Association.

Lavallée, P. (1994). *Ajout du second panel à l'EDTR: sélection et pondération*, document interne, Statistique Canada.

Lavallée, P. (1995). *Pondération transversale des enquêtes longitudinales menées auprès des individus et des ménages à l'aide de la méthode du partage de poids*, Techniques d'enquête, vol. 21, no 1, pp. 27-35.

Lavigne, M. et Michaud, S. (1998). *Aspects généraux de l'enquête sur la dynamique du travail et du revenu*, document de travail sur la dynamique du revenu et du travail, Statistique Canada, 75F0002M No. 98-05.

Lemaître, G. et Dufour, J. (1987). *Une méthode intégrée de pondération des personnes et des familles*, Techniques d'enquête, vol. 13, no 2, pp. 211-220.

Merkouris, T. (1999). *Cross-sectional Estimation in Multiple-Panel Household Surveys*, document de travail de la direction de méthodologie, Statistique Canada, HSMD-99-004E.

Nadeau, C., Gagnon, É. et Latouche, M. (1999). *Disclosure Control Strategy for the Release of Microdata in the Canadian Survey of Labour and Income Dynamics*, Proceedings of the Survey Research Methods Section, American Statistical Association.

Renaud, M. (1997). *Pondération transversale - Deuxième vague de l'EDTR* , document interne, Statistique Canada.

Singh, M.P., Drew, J.D., Gambino, J.G. et Mayda, F. (1990). *Méthodologie de l'enquête sur la population active du Canada*, Statistique Canada, Catalogue 71-526.

Statistique Canada (1997). *Répartition du revenu au Canada selon la taille du revenu*, publication de Statistique Canada N °13-207-XPB, pp. 52-59.

Tambay, J. L., Schiopu-Kratina, I., Mayda, J., Stukel, D. et Nadon, S. (1998). *Traitement de la non-réponse du cycle deux de l'enquête sur la santé de la population*, Techniques d'enquête, vol. 24, no 2, pp. 159-169.

Tremblay, J. (1998). *Détection des observations influentes pour l'enquête sur les finances des consommateurs (EFC) et l'enquête sur la dynamique du travail et du revenu (EDTR)*, document interne, Statistique Canada.

Annexe A : Liste des variables utilisées dans le modèle d'ajustement pour la non-réponse

Les variables dichotomiques suivantes ont été utilisées pour modéliser la non-réponse pour la cinquième vague du premier panel.

Aborig	- autochtone
Canada	- né au Canada
US	- né aux États-Unis
UK	- né au Royaume-Uni
Europe	- né en Europe
Autpays	- né ailleurs (pas au Canada, ni aux États-Unis, ni au Royaume-Uni, ni en Europe)
EOBR	- origine ethnique britannique
EOCAN	- origine ethnique canadienne
EOEUR	- origine ethnique européenne
EOFR	- origine ethnique française
IMSTAT	- statut d'immigration
VISMIN	- minorité visible
OWNER	- propriétaire
RURAL	- habite dans une région rurale (basé sur le secteur de dénombrement)
REMOTE	- habite dans une région éloignée (basé sur le secteur de dénombrement)
URBAIN	- habite dans une région urbaine (basé sur le secteur de dénombrement)
EMPLOYE	- personne occupée
NEMPLOYE	- chômeur
NLF	- inactif
MAR_UL	- marié ou vivant en union libre
SEP_DIV	- séparé ou divorcé
VEUF	- veuf ou veuve
CELIB	- célibataire, n'a jamais été marié
PROX	- l'interview préliminaire a été menée via une personne interposée
REV0	- indique si le revenu du ménage était manquant à l'interview préliminaire. Cette variable a été ajoutée pour l'année de référence 1997 puisque le taux de non-réponse pour cette variable était élevé : 29 %. Pour les années de référence précédentes, les données manquantes étaient incluses dans la même catégorie que REV1 (revenu du ménage <=10 000$).
REV1	- revenu du ménage <=10 000$
REV2	- revenu du ménage > 10 000$ et <=25 000$
REV3	- revenu du ménage > 25 000$ et <=50 000$
REV4	- revenu du ménage > 50 000$
PRESENF	- présence d'enfant(s) au moment de l'interview préliminaire
P10 – P59	- une variable pour chaque province
HOMME	- sexe
AGE_1	- age >=16 et <19
AGE_2	- age >=19 et <25
AGE_3	- age >=25 et <35
AGE_4	- age >=35 et <45
AGE_5	- age >=45 et <55
AGE_6	- age >=55 et <65
AGE_7	- age >=65
Educ1 – Educ9	- 9 niveaux de scolarité

Les variables dichotomiques suivantes ont été utilisées pour modéliser la non-réponse pour la deuxième vague du second panel.

Educ1	- 0-8 années de scolarité
Educ2	- 9-13 années de scolarité (études secondaires)
Educ3	- études post-secondaires excluant le collège communautaire, le CÉGEP et l'université
Educ4	- collège communautaire, CÉGEP ou université (incluant doctorat)
RENTER	- 1=propriétaire, 0=locataire
EMPLOYE	- personnes occupées
NON_EMPL	- chômeurs
NLF	- inactifs
MARIE	- marié ou vivant en union libre
SEP_DIV	- séparé ou divorcé
VEUF	- veuf ou veuve
CELIB	- célibataire, n'a jamais été marié
P10 – P59	- une variable par province
SEXE	- sexe
AGE_1	- age >=16 et <19
AGE_2	- age >=19 et <25
AGE_3	- age >=25 et <35
AGE_4	- age >=35 et <45
AGE_5	- age >=45 et <55
AGE_6	- age >=55 et <65
AGE_7	- age >=65
HHSZ1-HHSZ5	- nombre de personnes dans le ménage (HHSZ5=>5)
FAMTYPE1	- personne non apparentée
FAMTYPE2	- famille époux-épouse ou famille monoparentale sans jeune enfant
FAMTYPE3	- famille époux-épouse ou famille monoparentale avec des enfants âgés de 0 à 17 ans
FAMTYPE4	- autre genre de famille
STUDENTS	- 1=étudiant (à temps plein ou à temps partiel), 0=n'est pas un étudiant
CWORK1	- catégorie de travailleur = employé du secteur public
CWORK2	- catégorie de travailleur = employé du secteur privé
CWORK3	- est un travailleur indépendant du secteur privé avec ou sans employés ou est un travailleur familial non rémunéré